

DARLY GERALDO DE SENA JÚNIOR

UTILIZAÇÃO DE TÉCNICAS DE VISÃO ARTIFICIAL PARA
AJUSTE DA ADUBAÇÃO NITROGENADA EM TRIGO

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

VIÇOSA
MINAS GERAIS – BRASIL
2005

**Ficha catalográfica preparada pela Seção de Catalogação e
Classificação da Biblioteca Central da UFV**

T

S474u
2005

Sena Júnior, Darly Geraldo de , 1968-
Utilização de técnicas de visão artificial para ajuste
da adubação nitrogenada em trigo / Darly Geraldo de
Sena Júnior – Viçosa : UFV, 2005.
ix, 149f. : il. ; 29cm.

Orientador: Francisco de Assis de Carvalho Pinto
Tese (doutorado) - Universidade Federal de
Viçosa.

Inclui apêndice.

Referências bibliográficas: f. 113-120

1. Processamentos de imagens - Técnicas digitais.
2. Análise multivariada. 3. Trigo - Adubos e fertilizantes.
4. Adubação em cobertura. I. Universidade Federal de
Viçosa. II. Título.

CDD 22.ed. 621.367

DARLY GERALDO DE SENA JÚNIOR

UTILIZAÇÃO DE TÉCNICAS DE VISÃO ARTIFICIAL PARA
AJUSTE DA ADUBAÇÃO NITROGENADA EM TRIGO

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

APROVADA: 20 de janeiro de 2005.

Prof. Moacil Alves de Souza

Dr. Evandro Chartuni Mantovani

Prof. Daniel Marçal de Queiroz
(Conselheiro)

Dr. José Ronaldo Magalhães
(Conselheiro)

Prof. Francisco de Assis de Carvalho Pinto
(Orientador)

À Tatiana, pelo amor, paciência e compreensão.

À meus pais e minhas irmãs, pelo apoio em todos os momentos.

Aos amigos que surgiram na convivência em Viçosa.

Ofereço

AGRADECIMENTOS

À Deus, por todas as oportunidades.

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 pelo financiamento concedido durante o curso.

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

Ao Professor Daniel Marçal de Queiroz, Professor Nerilson Terra Santos e Dr. José Ronaldo Magalhães pela orientação, amizade e estímulo.

Ao Professor Joseph Kalil Khoury Jr., pela orientação extra-oficial e valiosas discussões estatísticas; aos professores Moacil Alves de Souza e Valterley Soares da Rocha e ao Dr. Evandro Mantovani pelo auxílio e valiosas sugestões no decorrer do trabalho.

Ao Professores Ricardo Capúcio, Haroldo Fernandes, Mauri Teixeira e Carlos Viliotti pelo auxílio e apoio no dia a dia no departamento.

Aos colegas e amigos do PROVISAGRO Enrique, Rodrigo, Adenilson, Diego, Murilo, José Marcelo, Diogo, Natanael, Eduardo, Mário, Elder, Leidy, Cristiano e Jean que tanto contribuíram para a realização do trabalho; aos amigos da área de Mecanização Agrícola: Gilton, Luizinho; Renato, Andréia, Fabiane, Alcir, Leonardo, Buda, Denílson e Sebastião pelo auxílio, amizade e bom convívio.

À meus pais, Darly e Ana, à D.Sônia, Sr. Diógenes, Zana, Evandro, Dr. Valdemar e Lêda pela amizade e incentivo para realização deste trabalho.

À Tatiana pelo carinho, estímulo, amizade e compreensão nas dificuldades e nos bons momentos durante o curso.

Sinceros agradecimentos a todos que colaboraram para que este trabalho fosse realizado.

BIOGRAFIA

DARLY GERALDO DE SENA JÚNIOR, filho de Ana Maria de Araújo Sena e Darly Geraldo de Sena, nasceu em Registro, SP, no dia 19 de julho de 1968.

Em março de 1990 concluiu o curso de Agronomia na Universidade Federal de Viçosa e em janeiro de 1993 concluiu o curso de Zootecnia na mesma universidade.

De 1993 a 1995 trabalhou como autônomo e de 1995 a 2000 como sócio-diretor da Datum Topografia, em Belo Horizonte – MG.

Em março de 2000 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 tese em fevereiro de 2002.

Em maio de 2002 iniciou o curso de doutorado em Engenharia Agrícola, área de concentração em Mecanização Agrícola na mesma instituição e submeteu-se à defesa de tese em janeiro de 2005.

ÍNDICE

RESUMO.....	vii
ABSTRACT	ix
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	7
2.1. Nitrogênio na agricultura	7
2.2. Nitrogênio na cultura do trigo	11
2.3. Avaliação do estado nutricional de nitrogênio	13
2.4. Agricultura de precisão e adubação nitrogenada	17
2.5. Reconhecimento de padrões e classificação	21
2.6. Avaliação de classificadores	28
3. MATERIAL E MÉTODOS	34
3.1. Implantação e condução dos experimentos	34
3.2. Desenvolvimento e avaliação de classificadores.....	36
3.3. Avaliação da resposta da cultura à adubação nitrogenada em cobertura e parcelamento.....	50
4. RESULTADOS E DISCUSSÃO.....	54
4.1. Etapa de desenvolvimento e avaliação de classificadores.....	54
4.2. Avaliação da classificação utilizando imagens, valores SPAD e teor de nitrogênio foliar	72
4.3. Avaliação da resposta da cultura do trigo à adubação nitrogenada em cobertura e parcelamento.....	104
5. RESUMO E CONCLUSÕES	111
6. REFERÊNCIAS BIBLIOGRÁFICAS	113
7. APÊNDICES.....	121

RESUMO

SENA JUNIOR, Darly Geraldo de, D.S. Universidade Federal de Viçosa, janeiro de 2005. **Utilização de técnicas de visão artificial para ajuste da adubação nitrogenada em trigo.** Orientador: Francisco de Assis de Carvalho Pinto. Conselheiros: Daniel Marçal de Queiroz, Nerilson Terra Santos e José Ronaldo Magalhães.

O principal objetivo da Agricultura de Precisão é otimizar o uso de insumos, sendo o nitrogênio tema de diversos trabalhos. Esse interesse decorre de seu custo elevado, risco de contaminação ambiental, potencial de resposta das culturas e dificuldade de quantificação de sua disponibilidade no solo. Uma estratégia utilizada para identificar a disponibilidade de nitrogênio no solo é utilizar as plantas como indicadores, explorando as características espectrais dos pigmentos foliares. Têm sido empregados medidores de clorofila e a medição da reflectância da cultura por meio de radiômetros ou câmeras, porém acredita-se que os sistemas de visão artificial tornem-se a opção mais viável. Poucos trabalhos exploram outras características das imagens como a textura ou a associação de informações de mais de um índice espectral. O objetivo do presente trabalho foi discriminar a necessidade de nitrogênio em trigo a partir da resposta espectral do dossel no visível e no infravermelho próximo, associada ou não a características de textura das imagens do dossel. Outro fator avaliado foi a associação de informações de imagens processadas por mais de um índice espectral em classificadores multivariados. A cultura do trigo foi implantada no campo em parcelas com adubação de plantio uniforme e duas adubações em cobertura, aos 15 e aos 35 dias após a emergência (DAE) totalizando cinco doses (0, 30, 60, 90 e 120 kg de N.ha⁻¹). Plantas de trigo foram cultivadas ainda em vasos, submetidas às cinco doses de N aplicadas dois DAE. Imagens foram obtidas utilizando uma câmera digital Duncantech MS 3100, em três épocas no campo: 8, 14 e 20 dias após a adubação em cobertura (DAA) e nos vasos aos 43 DAE. O teor de clorofila foliar foi estimado utilizando-se um medidor de clorofila SPAD 502 e o N foliar determinado por análises laboratoriais.

Avaliou-se a relação funcional entre as doses de N aplicadas, os valores SPAD e os valores de N foliar, nas plantas cultivadas no campo e em vasos. As imagens foram processadas obtendo-se nove imagens-índice, sendo quatro combinando as bandas do visível e cinco combinando bandas do visível e o infravermelho próximo. De cada imagem-índice das parcelas foram extraídas a média dos valores dos pixels e cinco medidas de textura (2º, 3º, 4º, 5º e 6º momentos do histograma), formando um vetor de características para cada imagem original. Das imagens dos vasos, processadas com os nove índices, foram criados vetores com a média dos pixels na imagem e a média dos pixels representando folhas. Classificadores estatísticos foram desenvolvidos para discriminar as classes definidas pelas doses de N utilizando para combinações dos nove índices. Os classificadores foram avaliados com a elaboração da matriz de erros com a técnica de validação cruzada deixando uma amostra de fora e cálculo do coeficiente kappa e exatidão global. Os valores SPAD e os valores de N foliar também foram utilizados para desenvolver classificadores e a exatidão da classificação acessada da mesma forma. Nos dois experimentos observou-se variação nos valores SPAD durante o desenvolvimento das plantas, o que dificulta o estabelecimento de valores críticos para identificar a deficiência ou suficiência de N. Utilizando-se os valores SPAD, foram necessários pelo menos 14 DAA para discriminação entre as doses de N. No experimento em vasos, uma discriminação adequada utilizando-se os valores SPAD só foi conseguida aos 27 DAE. Com a utilização das imagens, no campo foi possível discriminar as doses de N aos oito DAA, não se observando benefício pela utilização das características de textura. Aos 14 DAA, não houve diferença significativa entre os classificadores utilizando imagens e os valores SPAD, assim como entre esses e o classificador desenvolvido com os valores de N foliar aos 20 DAA. A associação de características provenientes de diferentes índices espectrais mostrou-se benéfica, uma vez que as melhores classificações foram obtidas com classificadores multivariados. De acordo com os resultados obtidos, verificou-se que é possível nas condições em que o trigo foi cultivado no campo, identificar e corrigir a deficiência de N durante o ciclo da cultura do trigo sem prejuízo à produtividade.

ABSTRACT

SENA JUNIOR, Darly Geraldo de, D.S. Universidade Federal de Viçosa, January of 2004. **Nitrogen recommendation in wheat using machine vision techniques.** Adviser: Francisco de Assis de Carvalho Pinto. Committee members: Daniel Marçal de Queiroz, Nerilson Terra Santos and José Ronaldo Magalhães.

The main goal of Precision Agriculture is to optimize the use of resources, and nitrogen has been the subject of several works. This interest comes from its cost, possibility of environmental pollution, response of the crops and difficulty of measurement of its availability on the soil. One strategy that has been focused is the use of the plants as sensors, taking advantage of the spectral properties of the pigments on the leaves, specially the chlorophyll. Chlorophyll meters and the crop reflectance measurement, using radiometers or cameras, have been used but probably cameras could be the most viable option. However, few works use other features on the images beside the reflectance, as the texture or the use of data extracted from more than one spectral index together. The objective of this work was to study the nitrogen doses discrimination from the spectral response of the wheat dossel on visible and near infrared images, associated or not with texture features. Other factor studied was the features association obtained from images processed with more than one spectral index to develop multivariate classifiers. The wheat crop was grown in plots with uniform base fertilizer and two topdressing N fertilization, at 15 and 35 days after emergency (DAE), reaching five doses (0, 30, 60, 90 e 120 kg of N.ha⁻¹). Wheat plants were also grown in pots, with the five doses of N applied two DAE. Images were taken using a Duncantech MS 3100 digital camera, at three stages in the field conditions, 8, 14 and 20 days after topdressing fertilization (DAF) and at 43 DAE in pots. The chlorophyll content of the leaves on the field was estimated using a SPAD 502 chlorophyll meter and the total N content of the leaves was determined on samples at laboratory. The relationship between the N applied, the SPAD values and the N content in the of the plants grown in field and on the pots

was evaluated. The images were processed so that nine index images were obtained, four using the visible bands and five using the visible bands and the near infrared band. From each index image were extracted the pixel's mean value and five texture measurements (2nd, 3rd, 4th, 5th and 6th moments of the histogram), so that a vector of features was created from each original image. From the images of the plants in pots, processed with the nine indexes, were created vectors of features with the mean value of the pixels on the image and the mean value of the pixels representing leaves. Statistical classifiers were developed to discriminate the classes defined by the N doses using combinations of the nine indexes. The classifiers were evaluated using the leaving one out cross validation technique, creating the error matrix and the overall accuracy and the kappa index calculation. The SPAD values and the N content were also used to develop classifiers and the accuracy of the classification accessed using the same technique. In both experiments, SPAD values variation was noticed during the growth of the plants, a fact that makes difficult the establishment of critical SPAD values to identify the deficiency or sufficiency of N. When the SPAD values were used, at least 14 DAF were necessary to discriminate between the N doses. In the experiment with pots, a good discrimination using the SPAD values was obtained only at 27 DAE. Using the images, in field condition it was possible to discriminate the N doses at eight DAF with no benefit of the use of texture features. At 14 DAF there was no difference between the classifiers using images and SPAD values. At 20 DAA, there was also no difference between these classifiers and the classifier developed using the N content of the leaves. The association of features from different spectral indexes had shown benefits, since the best results were obtained from multivariate classifiers. It was verified that it is possible to identify and correct the nitrogen deficiency during the growth station without reduction of the productivity of the wheat, on the growth conditions in field condition.

1. INTRODUÇÃO

A agricultura de precisão pode ser considerada como a habilidade em monitorar e acessar a atividade agrícola a nível local, com o objetivo de aumentar a eficiência do processo produtivo (QUEIROZ et al., 2000). Esse sistema apresenta-se como alternativa ao sistema convencional onde se assume que os valores médios das variáveis de produção são representativos, desconsiderando a variabilidade espacial. Essa assunção acarreta o manejo homogêneo das áreas agrícolas, o que pode levar à aplicação excessiva ou insuficiente de insumos em determinadas áreas.

A implementação da agricultura de precisão tem sido questionada devido à incerteza de sua viabilidade econômica (GOMIDE et al., 2000). Entretanto, a sua principal motivação, a otimização do uso dos insumos agrícolas, dificilmente pode ser ignorada. Além disso, na discussão dos aspectos econômicos muitas vezes a questão ambiental é relegada a segundo plano, talvez pela dificuldade de quantificação do seu benefício econômico. Acredita-se que uso otimizado dos insumos pode ser a resposta para a necessidade da produção de alimentos a um custo competitivo, com baixa agressão ao meio ambiente.

Dentre os insumos agrícolas atualmente utilizados, um dos que desperta maior preocupação é o nitrogênio. Esse é o nutriente mineral absorvido em maiores quantidades pelas culturas agrícolas e como muitas vezes o solo não é capaz de suprir o nitrogênio necessário, o uso de fertilizantes é obrigatório para a obtenção de produtividades adequadas (DIAS et al., 1996). Dessa forma, a maioria das culturas, especialmente as gramíneas, respondem fortemente à sua aplicação. O nitrogênio influencia o crescimento diferencial de órgãos e sistemas vegetais pois é indutor de processos metabólicos com efeitos sobre a absorção de outros macro e micronutrientes e sobre a alocação de matéria e energia pelas plantas (FERNANDES e ROSSIELO, 1986).

Apesar da importância do nitrogênio para produção de diversas culturas, ainda não existem métodos adequados de análise de N disponível (DIAS et al., 1996; GUIMARÃES, 1998; ARGENTA et al., 2002; ORTIZ-MONASTERIO, 2002). Um fator que concorre para isso é o fato de 97 a 99% do N do solo encontrar-se na forma de compostos orgânicos (GUIMARÃES, 1998). Para que esse nitrogênio seja absorvido pelas plantas a matéria orgânica deve ser mineralizada e esse processo sofre influência da temperatura, umidade, aeração, natureza da matéria orgânica, pH e outros fatores ambientais de difícil controle (GUIMARÃES, 1998). Além disso, as formas de N no solo ao contrário de elementos como o fósforo, não estão em equilíbrio estável e as formas inorgânicas apresentam grande mobilidade no perfil (DIAS et al., 1996). Sob condições normais em solos bem aerados, a forma predominante é o nitrato (FERNANDES e ROSSIELO, 1986). ORTIZ-MONASTERIO (2002) afirma que nitrato é um nutriente móvel e dinâmico, bastante afetado pelas propriedades do solo, clima, manejo de irrigação, fonte do fertilizante, método de aplicação e método de preparo do solo, dentre outros.

A perda de nitrato pode ser muito intensa por lixiviação em solos bem drenados ou por desnitrificação em áreas com drenagem deficiente. Este potencial poluidor é mais um fator que estimula os trabalhos com o nitrogênio. Em países desenvolvidos, o custo relativamente baixo dos adubos nitrogenados permite que os produtores utilizem altas doses desse fertilizante, na tentativa de prevenir redução na produtividade (SCHRÖDER et al., 2000). Porém a elevada mobilidade do nitrogênio no solo e as altas doses muitas vezes levam à contaminação de águas sub-superficiais (SCHEPERS et al., 1996; TUMBO et al., 2002). DIAS et al. (1996) citam que em países onde se usam doses elevadas de N nos cultivos, as leis ambientais exigem monitoramento regular da concentração de nitrato nos mananciais de água. Deve-se destacar ainda que a fixação industrial do N para produção de fertilizantes químicos é altamente dependente da energia proveniente de combustíveis fósseis. A amônia, matéria prima principal para produção de fertilizantes nitrogenados, exige para sua produção três componentes básicos: gás natural, vapor e ar. O processo que vem sendo utilizado atualmente no Brasil parte da reação de gás natural, basicamente metano (CH_4) com água. Os produtos dessa reação recebem a injeção de ar quente sob pressão (1000 °C e 27 atm) para formar a amônia (DIAS et al., 1996).

Em países em desenvolvimento, embora a preocupação ambiental também esteja presente, a relação entre custo do fertilizante e valor do produto é alta. Sendo assim, as taxas economicamente ótimas de adubação nitrogenada são mais baixas. Nessas condições, os produtores trabalham em uma situação em que as lavouras apresentam maior resposta à adubação nitrogenada e a redução na produção pode ser severa quando a necessidade de nitrogênio não é adequadamente suprida (SCHRÖDER et al., 2000).

De acordo com dados da FAO (EMBRAPA TRIGO, 2004), em 2003 a área mundial cultivada com trigo foi superior a 208 milhões de ha e a produção superior a 557 milhões de toneladas. Neste mesmo ano, no Brasil a área representou 1,2% e a produção 0,95% no contexto mundial. Na safra de 2003 os fertilizantes foram o item que, individualmente, mais onerou a produção, sendo responsável por 24,75% do custo total da lavoura de trigo (DE MORI e FERREIRA FILHO, 2003). De acordo com ORTIZ-MONASTERIO (2002), as áreas de trigo de primavera irrigado localizadas em países em desenvolvimento apresentam alto potencial produtivo mas exigem elevados níveis de insumos, sendo a deficiência de nitrogênio o problema nutricional mais difundido.

STAFFORD (2000) considera que uma das áreas prioritárias para viabilização da agricultura de precisão é o desenvolvimento de sensores automáticos. Com relação ao nitrogênio, devido à dificuldade de quantificação de sua disponibilidade no solo, pesquisadores vêm estudando maneiras de utilizar as plantas como indicadoras. A aplicação da reflectância para fins agrícolas teve início nos anos 70, quando espectrômetros de infravermelho foram usados para mensurar a clorofila em folhas de plantas (LUKINA et al., 1997). Alguns pesquisadores utilizaram medidores portáteis de clorofila (VARVEL et al., 1997; GUIMARÃES et al., 1999; AHMAD et al., 1999; XU et al., 2000; GIL et al., 2002; CARVALHO et al. 2003). Outros utilizaram técnicas de sensoriamento remoto (BAUSCH e DUKE, 1996; GOPALAPILLAI et al., 1998; BOEGH et al., 2002; HABOUDANE et al., 2002; GOEL et al., 2003; MUTANGA et al., 2003).

A utilização de medidores portáteis de clorofila e as técnicas de sensoriamento remoto exploram características espectrais dos pigmentos presentes nas folhas, especialmente a clorofila. De modo geral, espera-se que a tonalidade de verde das folhas se torne mais intensa com o aumento da disponibilidade de nitrogênio no solo. Entretanto, diferenças genéticas entre cultivares também são

reconhecidas por afetar a tonalidade de verde, além de outros fatores como o estágio de crescimento da cultura, o momento e forma de aplicação do nitrogênio (SCHEPERS et al., 1992) e estresse hídrico (SCHEPERS et al., 1996).

A reflectância da cultura pode ser avaliada por radiômetros, que permitem a medição em bandas espectrais específicas, ou por meio de imagens orbitais, aéreas ou obtidas a partir de equipamentos agrícolas (visão artificial). Com o desenvolvimento e popularização das câmeras digitais, acredita-se que sua utilização para medição da reflectância do dossel tornar-se-á um dos métodos mais viáveis economicamente. Além disso, as imagens de alta resolução obtidas com as câmeras digitais permitem a medição de outras características além da reflectância como, por exemplo, a textura. A principal desvantagem das câmeras digitais é a menor resolução espectral em relação aos radiômetros, mas é uma limitação que pode ser contornada pela utilização de filtros específicos na câmera.

Na literatura científica, são encontrados diversos trabalhos utilizando sistemas de visão artificial na área agrícola (GHAZANFARI et al., 1997; ZHANG et al., 1997; LEEMANS et al., 1998; STEENHOEK et al., 1999; TILLET et al., 2001; VARELLA et al., 2002; SENA JR et al., 2003). BORHAN e PANIGRAHI (1999) utilizaram sistema de visão artificial para estimar o teor de nitrogênio em folhas de batata. KACIRA et al. (1999) utilizaram este sistema para detecção de estresse hídrico, em plantas cultivadas em ambiente controlado. Embora os desafios para a implementação dos sistemas de visão artificial na área agrícola sejam grandes (STEWART e TIAN, 1998; TIAN e SLAUGHTER, 1998; KASSLER, 2001), os mesmos apresentam grande potencial de utilização para coleta de dados em agricultura de precisão (PINTO et al., 2001). Para o desenvolvimento desses sistemas, 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 de culturas é a utilização de índices espectrais (GOPALAPILLAI et al., 1998; SÉRÉLÉ et al., 2000; DIKER et al., 2001; HANSEN e SCHJOERRING, 2003). Trata-se de combinações entre bandas espectrais criadas com o objetivo de minimizar variações causadas por fatores externos e promover o realce dos objetos de interesse (HABOUDANE et al., 2002). 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.

No presente trabalho foi avaliada a hipótese de que a utilização de características de textura extraídas de imagens, associadas à resposta espectral do dossel de plantas de trigo pode aumentar a eficiência da classificação, utilizando um sistema de visão artificial. Essa hipótese baseia-se no fato de que a deficiência de nitrogênio manifesta-se primeiro nas folhas mais velhas, pois este é um nutriente bastante móvel na planta. Sendo assim, acredita-se que imagens de plantas bem nutridas apresentem uma textura mais uniforme que plantas mal nutridas. Além disso, plantas bem nutridas tendem a cobrir melhor o solo, o que também pode contribuir para uma textura mais uniforme.

Outra hipótese avaliada foi que a utilização de classificadores multivariados, com dados extraídos de imagens processadas com mais de um índice espectral, pode se mostrar vantajosa. Os diversos índices espectrais encontrados na literatura relacionam-se em maior ou menor grau com determinadas características das plantas ou do dossel, de acordo com as bandas utilizadas na sua composição. Sendo assim, cada um pode carregar um determinado tipo de informação, que podem promover aumento na eficiência de classificação, quando utilizados em conjunto.

Dessa forma, o objetivo geral desse trabalho foi avaliar a discriminação de doses de nitrogênio em plantas de trigo, cultivadas no campo e em vasos, a partir da resposta espectral do dossel no visível e no infravermelho próximo por meio de imagens digitais, medidor portátil de clorofila SPAD 502 e análises foliares de N.

Os objetivos específicos foram:

- Verificar o estágio de desenvolvimento mais adequado, em tempo hábil para adubação em cobertura, para discriminar entre diferentes doses de adubação nitrogenada, utilizando medidor portátil de clorofila, análises foliares e sistema de visão artificial com base em características de reflectância e textura do dossel das plantas.
- Desenvolver algoritmos para identificar o estado nutricional de nitrogênio utilizando-se um medidor portátil de clorofila, análises foliares e características espectrais e de textura de imagens digitais de alta resolução.

- Avaliar a discriminação das classes definidas pelas doses de N, utilizando-se classificadores estatísticos desenvolvidos apenas com características de reflectância e com características de reflectância e textura do dossel.
- Avaliar a discriminação das classes definidas pelas doses de N, utilizando-se classificadores estatísticos desenvolvidos com características obtidas a partir do processamento de imagens com diversos índices espectrais, isoladamente e em conjunto.
- Caracterizar a resposta da cultura de trigo à adubação nitrogenada em cobertura nas épocas tradicionalmente utilizadas para essa prática em função da metodologia desenvolvida.

2. REVISÃO DE LITERATURA

2.1. Nitrogênio na agricultura

De acordo com dados da International Fertilizer Industry Association, na safra 2001/02 foram consumidos no mundo 82,81 milhões de toneladas de nitrogênio na forma de fertilizantes nitrogenados. O consumo de fertilizantes no Brasil em 2003, de acordo com dados elaborados pela Secretaria de Política Agrícola / MAPA (MAPA, 2004), foi de aproximadamente 22,80 milhões de toneladas. Desse total, os adubos nitrogenados respondem por 2,22 milhões de toneladas.

A amônia é a matéria prima principal para produção de vários fertilizantes nitrogenados, como uréia, sulfato de amônio, monoamônio fosfato (MAP) e diamônio fosfato (DAP). Para a produção de amônia três componentes são necessários: gás natural, vapor e ar. No método atual de produção de amônia, o N reage com o H na presença de catalisadores sob alta temperatura (400 - 500°C) e pressão (200 - 1000 atmosferas). O processo que vem sendo utilizado atualmente no Brasil parte da reação de gás natural, basicamente metano (CH₄) com água. Os produtos dessa reação recebem a injeção de ar quente sob pressão (1000 °C e 27 atm) para formar a amônia (DIAS et al., 1996).

MALAVOLTA et al. (1986) citam Butler e Jones (1973) e afirmam que o nitrogênio, tanto nas plantas como nos animais, faz parte de aminoácidos, purinas, pirimidinas, pigmentos, nucleotídeos, proteínas entre outras funções. Além da sua participação na formação de proteínas, o nitrogênio é importante constituinte de ácidos nucleicos e da clorofila (Tisdale et al., 1985 citados por GUIMARÃES, 1998). O nitrogênio é indutor de processos metabólicos com efeitos sobre a absorção de macro e micronutrientes e sobre a alocação de matéria e energia pelas plantas,

resultando em crescimento diferencial de órgãos e sistemas vegetais (FERNANDES e ROSSIELO, 1986).

O nitrogênio é o nutriente mineral absorvido em maiores quantidades pela maioria das culturas e muitas vezes o solo é incapaz de suprir todo o nitrogênio necessário, tornando obrigatória a utilização de fertilizantes para a obtenção de produtividades adequadas (DIAS et al., 1996). Na cultura do trigo, a exigência de N por tonelada de grãos aumenta nos níveis de produtividade mais elevados (ORTIZ-MONASTERIO, 2002). As plantas absorvem o N nas formas de amônio e nitrato, sendo que o nitrato é a forma preferencial por grande parte das culturas (FERNANDES e ROSSIELO, 1986). A fonte primária de N para as plantas é o gás N_2 , que constitui cerca de 78% da atmosfera terrestre. Entretanto, para que possa ser absorvido pelas plantas ele precisa ser reduzido ou oxidado pela ação de microrganismos, por descargas elétricas na atmosfera ou fixado em processos industriais (DIAS et al., 1996). SCHRÖDER (2000) afirma que o nitrogênio deve ser utilizado com cuidado para maximizar o retorno econômico, reduzir a susceptibilidade da cultura a pragas e doenças, otimizar a qualidade da cultura, poupar energia e proteger o meio ambiente.

De acordo com GUIMARÃES (1998), apesar da importância do nitrogênio para produção de diversas culturas, ainda não existem métodos adequados de análise de N disponível, devido ao fato de 97 a 99% do N do solo se encontrar na forma de compostos orgânicos. Sendo assim, a quantidade de N disponível pode ser muito variável, pois ela depende da mineralização da matéria orgânica. As formas de N no solo, ao contrário de elementos como o fósforo, não estão em equilíbrio estável e as formas inorgânicas apresentam grande mobilidade no perfil (DIAS et al., 1996). ORTIZ-MONASTERIO (2002) discute que o nitrato é móvel e dinâmico, bastante afetado pelas propriedades do solo, clima, manejo de irrigação, fonte do fertilizante, método de aplicação e método de preparo do solo, dentre outros.

Em razão desse comportamento geral, não existe até o momento critério adequado para a recomendação de adubação nitrogenada com base em análises de solo. Por isso, a recomendação é feita levando-se em conta os resultados de experimentos, tipo de cultura, histórico de uso da área e outros (DIAS et al., 1996). Para a definição adequada da dose de N, é importante conhecer o nitrogênio requerido para dado nível de produtividade, eficiência no uso do fertilizante, nitrato residual no solo, teste de mineralização de N a partir da matéria orgânica, créditos

de N a partir de resíduos orgânicos, rotação com leguminosas e nitrato em água de irrigação. Entretanto, essas informações muitas vezes não estão disponíveis em países em desenvolvimento (ORTIZ-MONASTERIO, 2002).

De acordo com ORTIZ-MONASTERIO (2002) alguns autores recomendam a estimativa da exigência de N com base somente na exportação de N nos grãos, porque, na maior parte das vezes, a biomassa, exceto os grãos, retorna ao solo. Em países desenvolvidos, têm sido utilizados parâmetros de solo como por exemplo, os testes de capacidade e de intensidade. Os testes de capacidade levam em consideração o histórico da área e as propriedades do solo (Klausner et al., 1993, citados por ARGENTA et al., 2002); os testes de intensidade baseiam-se na quantidade de N mineral presente no solo, por meio de testes de pré-semeadura, pré-aplicação e de pós-colheita. Embora os testes de nitrato no solo sejam bastante utilizados nas áreas irrigadas dos Estados Unidos, nos países em desenvolvimento são raramente utilizados, especialmente devido às características de solo e clima (ORTIZ-MONASTERIO, 2002). Por outro lado, ORTIZ-MONASTERIO (2002) cita Meisinger (1984) que afirmou que a determinação da retirada de N por uma cultura que não recebeu nenhum fertilizante é o modo mais satisfatório para estimar o suprimento de N pelo solo em um dado sistema solo-cultura-clima. Este método integra os fatores de crescimento da cultura e dinâmica de N sob condições naturais. ARGENTA et al. (2002) argumentam que em países com agricultura mais avançada o uso do teor de matéria orgânica do solo como parâmetro indicador do nível de N no sistema solo/planta está sendo substituído por outros que indicam o nível de N no solo, em plantas individuais e em comunidades de plantas. Segundo DIAS et al. (1996) a maneira mais segura para a recomendação de N seria a condução, para cada local e cultura, de experimentos, por dois ou três anos, para a definição da melhor fonte, dose e época de aplicação ou parcelamento do elemento.

A Figura 1, adaptada de MALAVOLTA et al. (1986), ilustra a relação existente entre o crescimento ou produção e o teor de um elemento na planta.

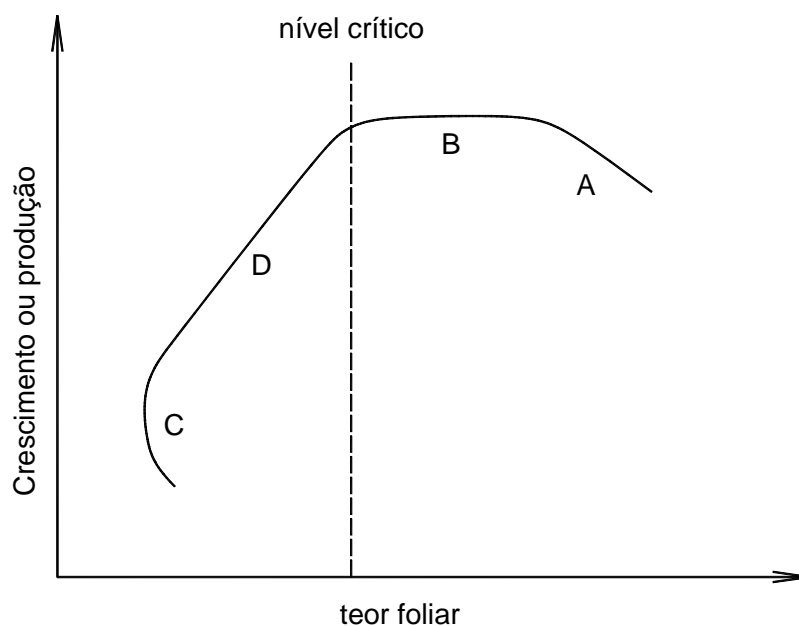


Figura 1. Relação entre o crescimento ou produção e o teor de um elemento na planta (MALAVOLTA et al., 1986).

MALAVOLTA et al. (1986) distinguem os vários segmentos da Figura 1, cada um com seu significado fisiológico. Na porção C, que recebe essa denominação devido à sua forma, os aumentos do crescimento estão associados à diminuição na concentração do elemento na matéria seca, que ocorre em plantas muito deficientes. Entre as várias explicações, está aquela segundo a qual a planta encontra-se com capacidade mais reduzida para absorver do que para crescer.

A porção D é conhecida como região das carências, onde a produção de matéria seca cresce de modo linear (ou quase linear) em resposta a incrementos nos teores do elemento. A região B é denominada região de alimentação de luxo, onde o teor do elemento cresce sem que ocorra aumento na produção. A porção A por sua vez é a região do excesso, desequilíbrio ou toxidez, onde o teor foliar continua a subir, entretanto a produção de matéria seca cai. Pode haver um excesso do elemento que pode ser tóxico ou a deficiência de outro devido à diminuição na absorção, por inibição competitiva ou não competitiva, no transporte ou na assimilação.

MALAVOLTA et al. (1986) destaca que a faixa separando os segmentos D e B é uma faixa de teores, geralmente denominados nível crítico, em que ocorre o

máximo de produção com absorção adequada do elemento. Esses teores estão associados com as exigências do elemento para intensidade máxima de processos como fotossíntese e intensidade mínima de outros processos como perdas de água na transpiração (MALAVOLTA et al., 1986).

MULLEN et al. (2003) citam trabalho de Raun e Johnson (1999) e afirmam que a eficiência estimada de uso de N na produção de cereais no mundo é em torno de 33%, o que sugere que as estratégias atualmente utilizadas para aplicação de N são extremamente ineficientes. ORTIZ-MONASTERIO (2002) cita Byerlee e Siddiq (1994) e afirma que a eficiência do uso do N no trigo cultivado sob irrigação é baixa. De acordo com esse autor, existem duas maneiras para aumento da eficiência do uso de N em trigo: melhoramento genético e manejo da cultura. MULLEN et al. (2003) sugerem que a aplicação de N somente é indicada quando existe expectativa de resposta da cultura pode aumentar a eficiência de uso do nutriente e a rentabilidade das culturas.

ORTIZ-MONASTERIO (2002) afirma que uma das mais importantes contribuições que a pesquisa agrônômica pode realizar para o aumento da eficiência do uso de nitrogênio em trigo irrigado é o desenvolvimento de testes diagnósticos adequados que podem auxiliar o produtor a identificar a taxa adequada de N.

2.2. Nitrogênio na cultura do trigo

De acordo com dados publicados a partir de dados da FAO (EMBRAPA TRIGO, 2004), no ano de 2003 a cultura do trigo ocupou no mundo uma área superior a 208 milhões de ha com uma produção de 557 milhões de toneladas. Desse total, o Brasil foi responsável por 1,2 e 0,95% da área cultivada e produção mundial, respectivamente. A área cultivada com trigo no Brasil foi superior a 2 milhões de ha em 2003, ocupando a 21ª posição mundial em termos de área plantada e a 28ª em termos de produção; neste ano a produtividade média brasileira foi de 2.174,5 kg.ha⁻¹. De acordo com planilha de custos elaborada pela Embrapa Trigo (DE MORI e FERREIRA FILHO, 2003) para a safra de 2003, o custo com fertilizantes de base e cobertura é responsável por 24,75% do custo total da lavoura de trigo, sendo o fator que individualmente mais onera a produção.

ORTIZ-MONASTERIO (2002) afirma que a maior parte do trigo de primavera irrigado está localizado em países em desenvolvimento, em áreas que apresentam

alto potencial produtivo mas que exigem elevados níveis de insumos, sobretudo fertilizantes nitrogenados. De acordo com KIRDA et al. (2001) a introdução de cultivares de trigo mais produtivas levou ao aumento do uso de fertilizantes nitrogenados na região do mediterrâneo, sem entretanto promover ganhos em termos de produtividade e qualidade, devido ao não atendimento de outras exigências da cultura.

A deficiência de N em trigo afeta principalmente a expansão foliar e a concentração de clorofila, ambos afetando diretamente a interceptação e eficiência de uso da radiação (ORTIZ-MONASTERIO, 2002). De acordo com KIRDA et al. (2001), diversos trabalhos já foram realizados acerca da época ideal de aplicação de N para adequá-la à absorção e utilização do N durante o ciclo da cultura do trigo; da mesma forma, os efeitos do parcelamento da adubação na eficiência do uso do N, no índice de colheita e perdas do N também foram abordados em várias situações (KIRDA et al. 2001 citando diversos autores). Esses estudos indicaram que o parcelamento das adubações nitrogenadas resultou em maior recuperação do nutriente pela cultura, maior índice de colheita e maiores produtividades quando comparados com aplicação única. Entretanto, a proporção do parcelamento deve ser determinada por local devido ao estado inicial de fertilidade do solo.

O efeito de doses e formas de parcelamento da adubação nitrogenada sobre características fitotécnicas da cultivar de trigo Embrapa 22, sob irrigação, foi estudado por COELHO (1997), no município de Coimbra, MG. Os tratamentos foram constituídos de quatro doses de N e quatro formas de parcelamento. O autor concluiu que as doses de N influenciaram as características acamamento, altura de plantas, índice de colheita, peso de mil grãos, peso hectolítrico e produtividade. As características estudadas, com exceção do acamamento de plantas e peso hectolítrico, não foram influenciadas pelo parcelamento.

De acordo com Moll et al. (1982) citados por ORTIZ-MONASTERIO (2002) a eficiência no uso do N (produção de grãos/N fornecido) pode ser dividida em dois componentes: eficiência de absorção ($N_{\text{total na planta}}/N_{\text{fornecido}}$) que mede a habilidade da cultura para retirar o N do solo e a eficiência de utilização (produção de grãos/ $N_{\text{total na planta}}$) que mede a capacidade da planta de converter o nitrogênio absorvido em produção de grãos.

As aplicações de N são mais eficientes com a cultura já implantada, entretanto, parece que certa quantidade de N é necessária mais cedo no ciclo da

cultura, particularmente quando o solo é altamente deficiente em N. Para que se possa coincidir com a demanda e o suprimento de N é importante identificar os períodos de elevada exigência de nitrogênio. ORTIZ-MONASTERIO (2002) cita Doerge et al. (1991) que mostraram que a absorção de N em trigo irrigado processa-se lentamente até o perfilhamento, até que se inicia a fase de alta demanda com a alongação do colmo e diferenciação da espiga. Aplicações tardias de N têm produzido bons resultados em comparação com a aplicação no plantio. Tem sido verificado que mesmo quando a planta do trigo tenha sofrido estresse por deficiência de N nos estádios iniciais da cultura uma aplicação de N no estágio fenológico Z31 promoveu maior recuperação do N aplicado, maiores produtividades e maior teor de proteína no grão. O estágio Z31 corresponde ao estágio Feekes 6, é o primeiro estágio do alongamento do colmo, onde ocorre a diferenciação floral.

FRIZZONE et al. (1996) desenvolveram trabalho combinando seis lâminas de irrigação e cinco doses de nitrogênio na cultura do trigo e obtiveram resultados confirmando existir interação positiva entre os dois fatores. A resposta da cultura à irrigação aumenta com o acréscimo nos níveis de nutrientes minerais, especialmente o nitrogênio. A análise dos dados mostrou resultados significativos para irrigação, nitrogênio e interação desses fatores. ORTIZ-MONASTERIO (2002) observou redução da produtividade em resposta a épocas de aplicação de 150 kg de N.ha⁻¹ após a diferenciação da espiga. Em outros trabalhos pouca ou nenhuma resposta foi observada à aplicação de N na antese.

MULLEN et al. (2003) citam trabalho de Johnson et al., (2000) em que se propõe um índice de resposta calculado a partir dos dados de colheita, obtido pela divisão da produção do tratamento mais produtivo, que recebeu N, pela produtividade do tratamento testemunha sem nitrogênio. Os autores afirmam que, embora teoricamente útil, esse índice não permite o ajuste da adubação nitrogenada durante o ciclo da cultura.

2.3. Avaliação do estado nutricional de nitrogênio

Os principais métodos utilizados para avaliação do estado nutricional de plantas são a identificação de sintomas de deficiência e excesso, análise de planta e diagnose foliar e testes bioquímicos (MALAVOLTA et al., 1986).

A identificação de sintomas de deficiência e excesso baseia-se no fato de que a falta ou excesso de um dado elemento mineral desencadeia uma série de

eventos sucessivos, iniciando-se com lesão molecular que leva a alteração subcelular. Em seguida ocorre modificação celular que, por sua vez, acarreta alteração no tecido. Essa seqüência advém do fato de que dado elemento exerce função ou grupo de funções que lhe são específicas, de modo que sua falta ou excesso provoca sempre a mesma alteração molecular, qualquer que seja a planta considerada. Sendo assim, no final da cadeia de eventos o sintoma visual de anormalidade é comum a todas as espécies (MALAVOLTA et al., 1986).

ORTIZ-MONASTERIO (2002) afirma que tem sido sugerida a utilização de testes periódicos de nitrogênio em tecidos das plantas para auxiliar no ajuste fino da adubação nitrogenada do trigo em condições irrigadas. STONE et al, (1996) citam trabalho de Elliot et al. (1987) em que foi demonstrado que a concentração de nitrato na base de hastes de trigo poderia ser utilizada para definir o estado nutricional de N durante o perfilhamento e para predizer a resposta em termos de produtividade ao nitrogênio aplicado. MALAVOLTA et al. (1986) citam que para o nitrogênio podem ser realizados os testes bioquímicos do teor de asparagina, redução de NO_3 , N amínico e N total.

ORTIZ-MONASTERIO (2002) cita ainda Vaughan et al. (1990) que indicaram que as concentrações de nitrato nos colmos e na planta foram altamente variáveis e têm uso limitado para recomendações de N. O trabalho sugeriu que o N total na planta ou folhas, no final do perfilhamento e início da elongação do colmo, poderia ser utilizado para predizer os requerimentos de N. Knowles et al. (1991), citados por ORTIZ-MONASTERIO (2002) concluíram que o uso dos valores de nitrato na base do colmo, durante o ciclo da cultura, em conjunto com uma análise de solo em pré-plantio, pode ser utilizada com sucesso para manejo intensivo de N em trigo irrigado. Os autores identificaram valores de deficiência, suficiência e excesso de N em diferentes estádios de desenvolvimento. Por outro lado, os autores sugeriram que a taxa de aplicação de N exata em cada uma das faixas definidas requer calibração local. LOPEZ-BELLIDO et al. (2004) trabalharam com trigo de inverno na Inglaterra, utilizando-se a mesma cultivar durante oito estações e doses de N de 0 a 300 $\text{kg}\cdot\text{ha}^{-1}$. O objetivo do trabalho foi verificar se a concentração de N nos perfilhos e folhas e valores SPAD na antese poderiam ser utilizados para predizer a porcentagem de N nos grãos na maturidade e a necessidade de adubação nitrogenada pós-antese para aumentar a proteína no grão. Concluíram que os valores de N nos perfilhos e folhas, assim como o medidor de clorofila apresentaram

potencial para predição do requerimento de N, entretanto os métodos exigem calibração para outras cultivares.

Dada a associação do nitrogênio com vários componentes celulares, como aminoácidos e ácidos nucléicos, o sintoma mais característico da sua deficiência é a redução na taxa de crescimento. Entretanto, na maioria das plantas, o primeiro sintoma da deficiência de N é a clorose das folhas mais velhas, devido à translocação do N contido nas mesmas para folhas mais novas (GUIMARÃES, 1998). Os caules tornam-se finos e duros, devido ao acúmulo excessivo de carboidratos que não são utilizados para a síntese de aminoácido e de outros compostos nitrogenados devido à baixa disponibilidade de N. Além disto, os carboidratos podem ser utilizados na síntese de antocianina, resultando no acúmulo deste pigmento nas folhas e nos caules de algumas espécies (GUIMARÃES, 1998). A disponibilidade de N afeta a taxa de inicialização e expansão, o tamanho final das e a taxa de senescência das folhas.

De acordo com ARGENTA et al. (2001), o teor de clorofila na folha é utilizado para predizer o nível nutricional de N em plantas devido ao fato de que a quantidade desse pigmento correlaciona-se positivamente com o teor de N na planta. CHAPMAN e BARRETO (1997) afirmam que a maior parte do N foliar está em enzimas associadas com a clorofila e as concentrações foliares de N afetam tanto o desenvolvimento como a fotossíntese do dossel de milho. Clorofilas e outros pigmentos não estão presentes somente nos cloroplastos, mas também associados às proteínas, formando estruturas complexas (Roux, 1982 citado por LOPEZ-CANTARERO et al., 1994).

HINZMAN et al. (1986) realizaram trabalho para verificar os efeitos da adubação nitrogenada na reflectância espectral e características agronômicas do trigo de inverno, utilizando-se duas doses de N (60 e 120 kg de N.ha⁻¹ e testemunha sem aplicação de N). A reflectância espectral foi medida 11 vezes durante o ciclo da cultura utilizando um espectralradiômetro na faixa de 400 a 2400 nm do espectro. Os autores concluíram que a fertilização com N em trigo reduziu a reflectância no visível e aumentou no infravermelho próximo. Essas mudanças ocorreram devido aos menores níveis de clorofila, menor área foliar e menor biomassa nas parcelas não fertilizadas. Os resultados demonstraram que plantas de trigo, sob deficiência de N, podem ser distinguidas de plantas sadias espectralmente. Dessa forma, imagens multiespectrais podem ser úteis para o monitoramento das condições da cultura. Os

autores acrescentam que, embora fosse sempre possível distinguir as parcelas com dose 0 kg de N.ha⁻¹ daquelas com dose 120 kg de N.ha⁻¹, as parcelas com 60 kg de N.ha⁻¹ nem sempre foram distinguíveis.

Uma forma que tem sido utilizada para avaliar a reflectância do dossel de culturas é a utilização de índices espectrais (GOPALAPILLAI et al., 1998; SÉRÉLÉ et al., 2000; DIKER et al., 2001; HANSEN e SCHJOERRING, 2003). Trata-se de combinações entre bandas espectrais criadas com o objetivo de minimizar variações causadas por fatores externos e promover o realce dos objetos de interesse (HABOUDANE et al., 2002). 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.

MULLEN et al. (2003) determinaram o relacionamento existente entre o índice de resposta ao nitrogênio com a razão entre o Índice de vegetação da diferença normalizado (NDVI) de parcela de trigo adubada com o de parcela não adubada, em Oklahoma nos Estados Unidos. No final do perfilhamento, com a folha bandeira expandida e no florescimento o índice de resposta foi adequadamente predito utilizando-se o NDVI. Os autores concluíram que esse índice é um método viável para identificação de campos onde existe potencial de resposta a N adicional.

MOGES et al. (2004) realizaram trabalho para determinar o relacionamento entre os índices NDVI e o índice de vegetação da diferença de verde normalizado (GNDVI) com a biomassa, N na planta e produtividade de grãos de trigo de inverno. As medições foram realizadas utilizando-se fotodiodos, que mediam tanto a reflectância da cultura quanto a radiação incidente. Quando avaliado em estádios de desenvolvimento específicos o NDVI mostrou-se mais correlacionado com biomassa que o GNDVI. Ambos os índices mostraram-se mais correlacionados com o N transportado na planta que com biomassa seca em cada estágio de desenvolvimento, mas sem vantagem comparativa de um sobre o outro. Os dois índices também se mostraram altamente correlacionados com produtividade de grãos e N nos grãos. Os autores consideraram que o NDVI só parece ser vantajoso para predição de biomassa, especialmente em estádios iniciais de desenvolvimento.

FREEMAN et al. (2003) afirmam que a predição da produtividade e/ou do teor de proteína no trigo antes da colheita podem permitir a geração de mapas de produtividade e estimativas realistas de produção. Dessa forma, conduziram um

trabalho para determinar o relacionamento entre medições espectrais, a partir do estágio fenológico feekes 8 (folha bandeira visível) até a maturação fisiológica, e a produtividade e proteína nos grãos. As medições espectrais foram feitas utilizando-se fotiodos no vermelho e no infravermelho próximo. Foi calculado o índice NDVI que se mostrou bem correlacionado com a produtividade, exportação de N nos grãos e na palha nos estádios feekes 9 (língua da folha bandeira visível) e 10 (emborrachamento). Entretanto na maturação esse relacionamento não foi observado. Nos locais e anos avaliados, não se observou relacionamento consistente entre o NDVI e o teor de N nos grãos ou na palha em qualquer estágio de crescimento.

VARELLA et al. (2003) utilizaram técnica de estatística multivariada para extrair um vetor de características de imagens aéreas digitais para discriminar níveis de nitrogênio em milho. Os dois primeiros componentes principais de seis índices espectrais foram capazes de realizar a discriminação.

2.4. Agricultura de precisão e adubação nitrogenada

O primeiro passo na implementação da agricultura de precisão é a identificação da existência de variabilidade espacial e/ou temporal dos fatores de produção. LARSCHEID et al. (1997) recomendam a combinação de três ou quatro mapas de produtividade da área, para que se distingam os fatores espaciais e temporais. Identificada a variabilidade, buscam-se então suas causas e a viabilidade do manejo localizado das mesmas. LOBELL et al. (2004) afirmam que, de acordo com a produtividade esperada e N disponível no solo, a aplicação de N em cobertura falha ao se aplicar dose única quando deixa de considerar a variabilidade espacial e temporal no fornecimento e demanda de N, resultando em desperdício significativo de N. Os autores citam ainda o trabalho de Dobermann et al. (2002) em que as aplicações localizadas de N em arroz na Ásia, aumentaram a eficiência de uso desse fertilizante em 30 a 40%. MOGES et al. (2004) citam trabalho de Wibawa et al. (1993) em que foi verificada uma variação no teor de nitrato no solo amostrado em uma grade de 15 m.

Dentre as técnicas de agricultura de precisão, ORTIZ-MONASTERIO (2002) considera particularmente interessante o uso de sensores que medem o índice de vegetação da diferença normalizado (NDVI). Outra técnica é a utilização de modelos

de crescimento de culturas. Com esses modelos, é possível calcular diariamente, a disponibilidade de N, a retirada de N e o crescimento da cultura, utilizando dados climáticos médios ou reais e parâmetros de solo e da cultura. Ao contrário dos outros métodos, os modelos de crescimento, podem estimar o lado ambiental dos efeitos da aplicação de N. ORTIZ-MONASTERIO (2002) acredita que será necessária a simplificação desses modelos para que possam ser utilizados por extensionistas ou produtores em países em desenvolvimento.

WOOD et al. (2003) realizaram trabalho em que utilizaram técnicas de sensoriamento remoto para monitorar a expansão do dossel das culturas do trigo e da cevada e ajustar as aplicações de nitrogênio a taxas variáveis. Os autores variaram a taxa de semeadura para obter diferencial inicial na cultura e os tratamentos foram comparados com o manejo tradicional. As doses aplicadas variaram abaixo ou acima da quantidade planejada se o crescimento da cultura estava acima ou abaixo do desejado. Nos dois campos estudados, os maiores benefícios foram obtidos com a dose similar à tradicional, porém aplicada de modo variável, ao contrário da aplicação uniforme ao longo das faixas. Os autores afirmam que resultados de estudos iniciais realizados entre os anos de 1997 a 2000 mostraram que a resposta das culturas ao nitrogênio pode variar espacialmente, mas mostrou-se altamente dependente de variações sazonais como precipitação e água disponível. A aplicação de doses mais elevadas de N em áreas com menor população inicial e redução da dose em áreas com alta população inicial promoveram ganhos de até $0,5 \text{ t.ha}^{-1}$ em comparação com o tratamento tradicional.

STONE et al. (1996) afirmam que relações empíricas entre índices vegetativos e biomassa foram relatadas por diversos pesquisadores e realizaram trabalho com o objetivo de determinar a relação entre a reflectância espectral em comprimentos de onda específicos com a produtividade e retirada de N em trigo. Buscaram avaliar ainda o potencial dessa característica para correção de deficiência de N durante o ciclo da cultura. Foi utilizada a reflectância espectral no vermelho e infravermelho próximo no perfilhamento e início da alongação do colmo utilizando sensores com base em fotodiodos. Com base em um índice de vegetação, foi determinada a aplicação de N à taxa variada com doses de 0 a 112 kg.ha^{-1} , em parcelas de 3x3 m. O índice utilizado foi altamente correlacionado com as estimativas da retirada de N pelo trigo em todos os estádios. A produtividade de grãos aumentou significativamente com a aplicação do N em cobertura, tanto nos

tratamentos com dose fixa como em taxa variada em relação à testemunha. Entretanto, não se observaram diferenças significativas de produtividade entre os tratamentos com dose fixa e taxa variável. As parcelas tratadas com N a taxa variada resultaram em economia de N entre 32 e 57 kg N.ha⁻¹.

LOBELL et al. (2004) desenvolveram um modelo para tomada de decisão quanto ao manejo de N que incorpora diagnósticos hipotéticos de N no solo e condições climáticas. O modelo foi utilizado para quantificar o potencial das previsões com relação à produtividade do trigo, lucro do produtor e aplicações excessivas de N. No cenário corrente, sem diagnóstico, a incerteza quanto ao solo e condições climáticas é responsável pela aplicação excessiva de N em torno de 35%. Os autores observaram que a variabilidade do solo é pelo menos 3 vezes mais importante que as variações climáticas em termos de impacto nas margens de lucro na região estudada. Os autores concluíram que trabalhos futuros são necessários para melhorar o diagnóstico de N no solo e condições climáticas, cujo custo deve ser comparado aos benefícios para determinar seu valor para o manejo da adubação nitrogenada.

WELSH et al. (2003) trabalharam com o objetivo de avaliar um grupo de estratégias para manejo de doses variáveis de nitrogênio com base em dados históricos de produtividade ou parâmetros da cultura obtidos em “tempo real”. De acordo com os autores esses dados poderiam fornecer informações sobre a possibilidade de, uma vez identificada variabilidade no potencial produtivo do campo, variar a dose de N. Os autores concluíram que o uso de mapas de densidade de plantas é mais promissor que a utilização de dados históricos para aplicação de N a taxas variáveis. Além disso, observaram que variações na estrutura da cultura podem ser monitoradas utilizando-se sensoriamento remoto, o que permite alterações nas práticas de manejo durante o ciclo da cultura para melhorar o desempenho da mesma.

EPIPHANIO e FORMAGGIO (1991) utilizaram índices de vegetação obtidos a partir de imagens TM/Landsat-5 e constataram relações entre os índices e parâmetros agrônômicos: índice de área foliar (IAF), porcentagem de cobertura vegetal (COV) e densidade de clorofila, em culturas de trigo e feijão irrigadas. De acordo com esses autores, quando se utiliza mais de uma banda espectral pode-se explorar de forma mais eficiente as características espectrais dos alvos, ao contrário do que quando se utiliza uma banda simples. Entretanto, quando o número de

bandas espectrais aumenta, há um acréscimo de dificuldade de integração de múltiplos dados (Mather, 1987 citado por EIPHANIO e FORMAGGIO, 1991). A utilização de índices espectrais tem como finalidade além do realce de características como biomassa, vigor e índice de área foliar, reduzir a dimensionalidade dos dados. De acordo com EIPHANIO e FORMAGGIO (1991) citando dados de Formaggio (1989) no caso do trigo, o IAF e a cobertura vegetal variam de modo relativamente interdependente: a cobertura cresce rapidamente no início do ciclo, ao passo que o IAF assume crescimento rápido por volta dos 30 dias de idade. Nessa época, a cobertura praticamente assume seu valor máximo. A partir daí a cobertura mantém-se no seu ponto de saturação máxima enquanto o IAF continua crescendo até por volta dos 47-50 dias e então começa a diminuir.

ADAMSEN et al. (1999) compararam três métodos para medição da senescência de plantas de trigo submetidas aos efeitos de reduzida disponibilidade de N e elevadas taxas de CO₂. As medições foram realizadas utilizando-se uma câmera digital, um medidor de clorofila SPAD e um radiômetro portátil. Foi utilizada a razão verde-vermelho obtida a partir das imagens, o índice de vegetação da diferença normalizado obtido a partir dos dados do radiômetro e os valores SPAD coletados na folha bandeira das plantas. Os autores concluíram que os três métodos apresentaram resultados temporais semelhantes. Entretanto verificou-se que as medições do dossel (índices) mostraram-se mais sensíveis à senescência incipiente que o SPAD que utilizava observações pontuais no topo do dossel.

HANSEN e SCHJOERRING (2003) utilizaram dados de reflectância espectral em cinco estádios de crescimento da cultura do trigo de inverno em um experimento 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, com 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.

2.5. Reconhecimento de padrões e classificação

O reconhecimento de padrões concretos por seres humanos pode ser considerado um problema psico-sociológico que envolve o relacionamento entre a pessoa e estímulos físicos. Ao perceber um padrão a pessoa realiza inferências indutivas e associa essa percepção com conceitos gerais ou indícios derivados por ela a partir de experiências passadas. O desenvolvimento de teorias e técnicas para o desenvolvimento de sistemas capazes de realizar reconhecimento é uma área de estudo da engenharia, informática e ciência da informação. Sendo assim, o reconhecimento de padrões pode ser definido como a categorização dos dados de entrada em classes identificáveis pela extração de características significantes ou atributos dos dados (TOU e GONZALES,1974).

TOU e GONZALES (1974) afirmam que o desenvolvimento de qualquer sistema automático de reconhecimento de padrões geralmente envolve três aspectos: a representação dos dados de entrada obtidos a partir dos objetos a serem classificados; a extração das características peculiares dos dados de entrada que são relevantes para uma dada aplicação, ou seja, a seleção do melhor sub-grupo de variáveis discriminantes; e por fim a escolha do procedimento de decisão, ou seja, a escolha do classificador. JAYAS et al. (2000) assinalam que a escolha do classificador para determinada aplicação sempre envolve algum grau de experimentação. JAYAS et al. (2000) citando Hush e Horne (1993) afirmam que, embora para alguns problemas a maioria dos classificadores produza resultados similares, a diferença reside no tempo de processamento, exigência quanto ao armazenamento de dados e grau de exatidão.

Quando padrões representativos das classes em estudo estão disponíveis, pode-se utilizar técnicas de reconhecimento de padrões supervisionadas. Nesse ambiente de aprendizado, o sistema é “ensinado” por meio de padrões de treinamento com classificação conhecida. Em outras aplicações, entretanto, somente um grupo de padrões de treinamento não classificado está disponível, em que se aplicam as técnicas de reconhecimento de padrões não supervisionadas. Em ambas as metodologias, o desempenho do reconhecimento será influenciado pela similaridade dos dados de treinamento com os dados reais a que o sistema será confrontado em condições normais de operação (TOU e GONZALES, 1974).

De acordo com TOU e GONZALES (1974), três principais metodologias podem ser utilizadas para o reconhecimento automático de padrões: heurística, matemática ou sintática.

Os métodos heurísticos baseiam-se na intuição humana e experiência, sendo que os sistemas desenvolvidos utilizando esse princípio, em geral, consistem de um grupo de procedimentos. Cada problema requer a aplicação de regras de decisão especializadas, de forma que a estrutura e desempenho dependem da experiência e capacidade de seus criadores. Os métodos matemáticos baseiam-se em regras de classificação que são formuladas e derivadas em uma estrutura matemática, utilizando propriedades comuns e conceitos de agrupamento. Esses métodos podem ser divididos em determinísticos e estatísticos.

Os métodos determinísticos baseiam-se em uma estrutura matemática que não emprega explicitamente as propriedades estatísticas das classes em consideração. Os métodos estatísticos por sua vez baseiam-se em regras de classificação matemática que são formuladas e derivadas em uma estrutura estatística. De acordo com Duda e Hart (1973) citado por JAYAS et al. (2000), os métodos estatísticos baseiam-se na regra de erro mínimo de Bayes:

$$m \in \Omega_k \text{ se } P(w_k/m) > P(w_j/m) \quad \forall j \neq k$$

em que,

m = vetor de características de um objeto desconhecido; e

$P(w_j/m)$ = probabilidade a posteriori de que um objeto com um vetor de características m pertença à classe w_j .

A regra afirma que para minimizar a probabilidade média de erro, um objeto deveria ser classificado como pertencente à classe w_i que maximiza a probabilidade a posteriori $P(w_i/m)$. Uma formulação mais prática pode ser obtida com a aplicação do teorema de Bayes (JAYAS et al., 2000):

$$P(w_i/m) = P(w_i)p(m/w_i)/p(m) \quad (1)$$

obtendo-se:

$$m \in \Omega_k \text{ se } P(w_k)p(m/w_k) > P(w_j)p(m/w_j) \quad \forall j \neq k$$

em que,

$P(w_i)$ = probabilidade a priori de que um objeto venha da classe w_i ;

$p(m)$ = função densidade probabilidade de m ; e

$p(m/w_i)$ = função densidade probabilidade condicional da classe para m .

Na maior parte das aplicações a probabilidade a posteriori ou a função densidade probabilidade (FDP) condicional da classe é desconhecida, e sendo assim, necessita ser estimada. Sua estimativa pode ser feita de duas maneiras, com métodos paramétricos e não paramétricos (JAYAS et al., 2000).

O método paramétrico usualmente assume que a FDP condicional da classe, m , $p(m/w_i)$ tem a forma de uma distribuição normal multivariada. Sendo assim, para estimar a densidade probabilidade, é necessário estimar os parâmetros média (μ_i) e variância (Σ_i). JAYAS et al. (2000) citando Hand (1981) afirmam que essa estimativa pode ser realizada a partir dos dados de treinamento por diversos métodos, assim como a probabilidade a priori $P(w_i)$. Essa estimativa permite que o critério de classificação seja determinado em uma forma analítica.

O método não paramétrico calcula a probabilidade a posteriori $P(w_i/m)$ diretamente dos dados de treinamento, sem assumir nenhum tipo de distribuição para a densidade probabilidade (JAYAS et al., 2000).

Segundo os autores, os métodos paramétricos têm a vantagem de que o critério de classificação é derivado de uma forma analítica que pode ser facilmente transferida para um programa de classificação em um computador. Entretanto, a assunção da distribuição normal multivariada feita para a FDP condicional das classes na derivação do critério de classificação pode ser incorreta ou insuficiente em muitas aplicações e levar a erros de classificação significativos. Os métodos não paramétricos eliminam a necessidade de se assumir subjetivamente uma distribuição, estimando diretamente a probabilidade a posteriori a partir do conjunto de treinamento. A desvantagem desse método reside em que o critério de classificação derivado não pode ser expresso analiticamente. Isso significa uma grande exigência em memória e classificação mais lenta.

De acordo com Rosenblat (1958), citado por JAYAS et al. (2000), a estimativa da probabilidade a posteriori apresenta um viés na direção dos valores maiores. JOHNSON e WICHERN (1998) salientam que a interação entre tentativa de assumir uma distribuição de probabilidade e a forma do classificador resultante é muito

importante. Muitas vezes tenta-se discriminar com grande número de variáveis, algumas do tipo presença/ausência ou 0/1. Nessas situações e outras com faixas limitadas para as variáveis, assumir normalidade multivariada pode não ser uma opção adequada.

Os classificadores podem ser agrupados em classificadores supervisionados e não supervisionados. Os classificadores não supervisionados requerem apenas um mínimo de informações, onde as operações são realizadas procurando agrupamentos naturais dos valores das características. O sistema seleciona as médias e matrizes de co-variância das classes a serem utilizadas. Uma vez realizada a classificação o usuário realiza a atribuição a posteriori das classes naturais às classes de interesse. Muitas vezes não é tarefa simples, pois alguns agrupamentos podem representar classes misturadas, o que pode exigir esforço do usuário para atribuição (JENSEN, 1996).

VIEIRA (2000) cita que os algoritmos não supervisionados podem ser divididos em paramétricos e não paramétricos. No caso dos paramétricos, o algoritmo busca minimizar os valores de uma função assumida como a solução desejada. Quando não paramétricos, o algoritmo busca extrair informações dos dados de acordo com alguma regra heurística. De acordo com JENSEN (1996), centenas de métodos de agrupamento foram desenvolvidos, com diferente eficiência de acordo com os dados. Segundo VIEIRA (2000) essencialmente baseiam-se na repetição da classificação e reclassificação dos pixels.

Na área de sensoriamento remoto, para a utilização dos classificadores supervisionados, o analista identifica áreas na imagem pertencentes a cada classe de interesse da qual ele tenha conhecimento detalhado. Esses pixels são denominados como referência sendo que então o classificador identifica áreas que sejam estatisticamente similares a eles (VIEIRA, 2000). De modo geral é o tipo de classificador utilizado quando estão disponíveis amostras das classes devidamente identificadas.

De acordo com GONZALES e WOODS (2000), os classificadores de padrões por funções de distância tratam-se dos mais simples e intuitivos métodos de classificação. A motivação para o uso dessas funções advém do fato que a maneira mais óbvia de se estabelecer uma medida de similaridade entre vetores de padrões é determinando a sua proximidade. Espera-se que esse método produza resultados práticos e satisfatórios apenas quando as classes tendem a se apresentar

agrupadas. Nesse método, algoritmos de agrupamento de classes desempenham papel importante. Uma vez que a proximidade de um padrão desconhecido ao padrão das classes será utilizado para sua classificação, utiliza-se o termo classificador de distância mínima (GONZALES e WOODS, 2000).

Cada classe é representada por um vetor protótipo ou médio dos vetores das características dos elementos que compõem a classe. Uma maneira de classificar um vetor desconhecido a uma classe é atribuí-lo à classe cujo vetor médio esteja mais próximo. Pode-se utilizar a distância euclidiana para determinar a proximidade, reduzindo o problema à computação de distâncias e avaliação das funções (GONZALES e WOODS, 2000):

$$d_j(x) = x^T m_j - 0,5 m_j^T m_j \quad j=1,2,\dots,M \quad (2)$$

em que,

x = vetor desconhecido;

m_j = vetor médio da classe j ;

m_j^T = vetor médio da classe j transposto; e

M = número de classes.

O vetor x será atribuído à classe w_i quando $d_i(x)$ for o maior valor numérico. A fronteira de decisão que separa as classes w_j e w_k é dada pelos valores de x para os quais $d_j(x) = d_k(x)$. Essa fronteira é dada pela equação 3:

$$x^T(m_j - m_k) - 0,5(m_j - m_k)^T(m_j - m_k) = 0 \quad (3)$$

A superfície dada pela equação 3 é a bissetão perpendicular do segmento de linha entre m_j e m_k . Para $n=2$, a bissetão perpendicular é uma linha, para $n=3$ é um plano e para $n>3$ é um hiperplano (GONZALES e WOODS, 2000). Esse classificador funciona bem na prática quando a distância entre as médias for grande em relação à dispersão de cada classe em relação à sua média. O classificador de distância mínima leva a uma classificação ótima quando a distribuição de cada classe em torno de sua origem for na forma de uma “hiper-nuvem” esférica no espaço n -dimensional de padrões. Entretanto essa forma de distribuição e com grande separação entre médias dificilmente ocorre na prática, a não ser que exista algum tipo de controle sobre a entrada de dados (GONZALES e WOODS, 2000).

A maior parte dos métodos estatísticos é também chamada de paramétrica no sentido em que o comportamento do classificador é controlado por parâmetros da

distribuição estatística utilizada para modelagem dos dados amostrais. O método da máxima verossimilhança gaussiana é muito utilizado e baseia-se em assumir que as funções densidade probabilidade $p(x/w_i)$ para cada classe w_i apresentam distribuição normal (de Gauss) (VIEIRA, 2000). COSTA (1999), citando Swain e Davis (1978), afirma que o classificador da máxima verossimilhança é um dos mais utilizados pela sua robustez, uma vez que sua exatidão não é muito afetada por violações da pressuposição de multinormalidade dos dados de treinamento. Entretanto, Cortijo e La Blanca (1997), citados por COSTA (1999), afirmam que a classificação gerada por esse classificador é de baixa exatidão quando ocorre grande superposição entre os dados de treinamento no espaço n-dimensional formado por n-bandas.

A distribuição normal descreve a probabilidade de uma única variável e é especificada por dois parâmetros – a média e a variância. Quando mais de uma variável está envolvida, torna-se necessário utilizar a distribuição normal multivariada, que é uma generalização da distribuição normal. Ao contrário da distribuição normal, em que a média controla a localização da distribuição, existe uma média de cada variável envolvida gerando-se um vetor de médias e o equivalente multivariado da variância é a matriz de variâncias e co-variâncias (VIEIRA, 2000). Esses parâmetros são computados para as amostras de cada classe e tornam-se os parâmetros que descrevem cada classe. O processo de treinamento consiste na estimativa da função de probabilidade gaussiana conjunta, selecionando-se amostras de cada classe (VIEIRA, 2000).

GONZALES e WOODS (2000) demonstram a obtenção das funções de decisão envolvendo duas classes de padrões ($M=2$), que apresentam distribuição normal, com médias m_1 e m_2 e desvios padrão σ_1 e σ_2 , respectivamente. Os padrões são escalares, denotados por x . Para esse caso, as funções de decisão, $d_j(x)$, possuem a forma:

$$d_j(x) = \frac{1}{\sigma_j \sqrt{2\pi}} \exp\left[-\frac{(x-m_j)^2}{2\sigma_j^2}\right] P(w_j) \quad j=1,2 \quad (4)$$

em que,

σ = desvio padrão da classe;

m = vetor de médias das classes; e

$P(w_j)$ = frequência relativa da classe w_j .

Para o caso n dimensional, cada densidade é especificada por seu vetor de média m_j e matriz de covariância C_j . Devido à forma exponencial da densidade gaussiana, utiliza-se o logaritmo natural da função de decisão probabilidade, obtendo-se a equação (GONZALES e WOODS, 2000):

$$d_j(x) = \ln P(w_j) - \frac{1}{2} \ln |C_j| - \frac{1}{2} [(x - m_j)^T C_j^{-1} (x - m_j)] \quad (5)$$

em que,

x = vetor desconhecido;

$|C_j|$ = determinante da matriz de covariância da classe j ; e

m_j = vetor de médias da classe j .

De acordo com GONZALES e WOODS (2000), se as matrizes de covariância forem iguais, chega-se à equação:

$$d_j(x) = \ln P(w_j) + x^T C^{-1} m_j - \frac{1}{2} m_j^T C^{-1} m_j \quad (6)$$

Além disso, se $C=I$, que é a matriz identidade e as probabilidades a priori das classes foram iguais, a regra de decisão é reduzida à equação 2 (GONZALES e WOODS, 2000):

JENSEN (1996), citando Hord (1982), afirma que o classificador de máxima verossimilhança assume que as classes apresentam probabilidades a priori iguais, ao contrário da regra de decisão de Bayes. O mesmo autor cita Strahler (1980) e afirma que as probabilidades a priori das classes têm sido usadas em sensoriamento remoto melhorando a exatidão da classificação.

VIEIRA (2000) afirma que embora normalidade assumida algumas vezes não seja observada na prática, esse classificador geralmente apresenta bons resultados e que a função de densidade normal multivariada é bastante utilizada pela facilidade analítica. Esse método de classificação é bastante utilizado em sensoriamento remoto e muitas vezes utilizado como método padrão para comparação com outros classificadores (VIEIRA, 2000). Entretanto, JENSEN (1996) afirma que o método é mais exigente computacionalmente que os métodos do paralelepípedo e da distância mínima e nem sempre fornecem melhores resultados.

De acordo com VIEIRA, (2000) a eficácia desse classificador depende da eficiência dos estimadores, ou seja, o quanto o vetor de médias amostrais M se aproxima do vetor de médias da população μ . Similarmente a afirmativa também é

válida para a matriz de variância e covariância amostral (S) e populacional (Σ). A eficiência depende do número de amostras, ou seja, a subamostragem pode prejudicar seriamente o desempenho. VIEIRA (2000) cita o “fenômeno Hughes”, em que se observa maior dificuldade na classificação quando a dimensionalidade dos dados aumenta enquanto o tamanho da amostra de treinamento permanece constante.

Foddy et al. (1992), citados por JENSEN (1996), sugeriram que as probabilidades a posteriori desse classificador poderiam ser utilizadas para avaliar a confiabilidade da classificação de cada pixel permitindo ao usuário definir um valor mínimo de probabilidade a posteriori para aceitação da classificação de pixels ou regiões. Aqueles cuja classificação fosse rejeitada poderiam ser submetidos a novo treinamento e classificação.

2.6. Avaliação de classificadores

Mather (1999), citado por VIEIRA (2000), sugere que o último estágio no reconhecimento de padrões é a avaliação da exatidão, para que o produto possa ser utilizado e aceito. De acordo com SAS (1999), o critério de classificação deve ser avaliado de acordo com seu desempenho na classificação de futuras observações. No procedimento PROC DISCRIM do programa computacional SAS a estimativa da contagem de erros é calculada aplicando-se o critério desenvolvido a um conjunto de dados. A taxa de erro na classificação de cada grupo é a proporção das amostras daquele grupo que foram classificadas incorretamente (SAS, 1999).

Glick (1978) citado por SAS (1999), sugeriu a utilização da estimativa da taxa de erro suavizada. Ao contrário de proceder à soma de termos que são valores zero e um, como na estimativa da taxa de erro por contagem, essa metodologia usa valores contínuos entre zero e um nos termos a serem somados. Isso dá origem a um estimador com menor variância que na estimativa por contagem de erros.

A estimativa da probabilidade a posteriori para cada grupo baseia-se na probabilidade da observação ser classificada no mesmo grupo. Essa probabilidade é uma boa estimativa da taxa de erro quando as probabilidades a posteriori são exatas. Quando um critério de classificação paramétrico (função discriminante linear ou quadrática) é derivado de uma população não normal, as estimativas da probabilidade a posteriori das taxas de erro podem não ser apropriadas. A taxa de

erro geral é estimada por meio de uma média ponderada das estimativas das taxas de erro específicas de cada grupo, onde as probabilidades a priori são utilizadas como pesos (SAS, 1999).

Quando o conjunto de testes é independente, a estimativa da taxa de erro não apresenta viés, entretanto a variância pode ser grande, especialmente se o conjunto de teste for pequeno (SAS, 1999). Quando o mesmo conjunto de dados é utilizado tanto para definir como para avaliar o classificador, a contagem de erro obtida apresenta um viés otimista e é denominado taxa de erro aparente. Para reduzir o viés o conjunto de dados pode ser dividido em dois, um para obtenção da função discriminante e outro para a estimativa da taxa de erro. A desvantagem desse método é a redução do tamanho da amostra (SAS, 1999). De acordo com Lachenbruch e Mickey (1968) citados por SAS (1999), uma maneira de reduzir o viés é a validação cruzada. JOHNSON e WICHERN (1998) referem-se a essa metodologia como *Lachenbruch's holdout procedure* e que segundo esses autores é também conhecida por *jackknifing* ou *cross-validation* (validação cruzada). 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. Esse método consegue uma estimativa praticamente sem viés, mas com a variância relativamente grande (SAS, 1999). Hora e Wilcox (1982) citados por SAS, (1999), computam as estimativas de probabilidade a posteriori utilizando a validação cruzada. As estimativas resultantes tendem a apresentar baixa variância da estimativa da probabilidade a posteriori e baixo viés da validação cruzada.

CONGALTON (1991) 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 (inclusão) e de omissão (exclusão) presentes na classificação. Uma matriz de erros é um arranjo quadrado em linhas e colunas e que expressa o número de amostras atribuídas às diferentes categorias ou classes. As colunas usualmente representam os dados de referência enquanto as linhas indicam os resultados da classificação. De acordo com CONGALTON (1991) a matriz de erros é o ponto de partida para uma série de técnicas estatísticas descritivas e analíticas. O autor sugere que a técnica descritiva

mais simples talvez seja a exatidão global, que pode ser computada dividindo-se o total de amostras corretamente classificadas (a diagonal da matriz de erros) pelo número total de pixels na matriz. A exatidão global pode ser calculada utilizando-se a equação 7:

$$EG = \frac{\sum_{i=1}^c x_{ii}}{n} 100 \quad (7)$$

em que,

EG = exatidão global da classificação;

x_{ii} = valor na linha i e coluna i (diagonal) da matriz de erros;

n = número total de amostras; e

c = número total de classes.

Uma vez que a exatidão global não indica a exatidão nas diferentes classes, uma medida da exatidão mais detalhada é derivada da matriz de erros na forma da exatidão das classes individualmente. Esses valores podem ser obtidos dividindo-se o número total de amostras corretamente classificadas na classe pelo número total de amostras daquela classe (VIEIRA, 2000).

CONGALTON (1991) afirma que tradicionalmente utiliza-se o número total de amostras da classe submetidas à classificação (desconsiderando-se os erros de comissão) para cálculo da exatidão das classes. Uma vez que ao responsável pela classificação (produtor) interessa o quanto uma determinada área foi corretamente classificada. Dessa forma, quando se utiliza o número total de classes submetidas à classificação, o valor encontrado é denominado exatidão do produtor (producer's accuracy). Por outro lado, se for utilizado o número de amostras efetivamente atribuídas às classes (incluindo os erros de comissão) o valor encontrado é denominado exatidão do usuário (user's accuracy). De acordo com CONGALTON (1991), a exatidão do produtor indica a probabilidade de uma amostra ser corretamente classificada e é uma medida do erro de omissão. Por outro lado, a exatidão do usuário indica a probabilidade de um pixel classificado na imagem realmente representar aquela classe no solo, e é uma medida dos erros de comissão (STORY e CONGALTON, 1986).

Entretanto, CONGALTON (1991) em sua revisão afirma que essas técnicas serão de pouco valor se outros fatores não forem considerados, pois podem

influenciar a confiabilidade da matriz de erros: a coleta de dados de referência, o esquema de classificação utilizado, autocorrelação espacial, tamanho da amostra e esquema de amostragem.

VIEIRA (2000) comparou três tipos de classificadores: distância mínima, máxima verossimilhança e redes neurais artificiais. Para avaliar a exatidão da classificação utilizou medidas baseadas na matriz de erros: exatidão global, exatidão das classes individuais, exatidão do produtor e exatidão do usuário.

Cohen (1960), citado por ROSENFELD e FITZPATRICK-LINS (1986), desenvolveu um coeficiente de concordância (denominado kappa) para escalas nominais. CONGALTON e MEAD (1983) afirmam que essa é uma técnica de análise estatística multivariada discreta que pode ser utilizada, pois os dados em uma matriz de erros são discretos e multinomialmente distribuídos. Afirmam ainda que estatísticas paramétricas assumem que os dados são contínuos e normalmente distribuídos e que um teste de qui-quadrado poderia ser utilizado, mas algumas células na matriz podem apresentar o valor zero. De acordo com CONGALTON e MEAD (1983), essa estatística é uma medida do acerto real menos o acerto por acaso. O acerto real é o próprio valor da célula e o acerto por acaso é definido como o produto dos marginais (totais de linhas e colunas) (CONGALTON e MEAD, 1983). De acordo com ROSENFELD e FITZPATRICK-LINS (1986), o coeficiente kappa pode ser definido de acordo com a equação 8:

$$\hat{K} = \frac{P_o - P_c}{1 - P_c} \quad (8)$$

em que,

\hat{K} = estimativa do coeficiente Kappa;

P_o = proporção de unidades corretamente classificadas; e

P_c = proporção esperada de acerto por acaso.

O coeficiente kappa leva em consideração toda a matriz de erros, incluindo os erros de omissão e de comissão. Porém VIEIRA (2000) cita Rutchey e Vilcheck (1994) e Congalton e Green (1999) e ressalta que por essa metodologia, ao se computar os totais marginais, as amostras não reconhecidas são desconsideradas. A equação 9 pode ser utilizada para estimativa do coeficiente kappa, conforme HUDSON e RAMM (1987).

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

em que,

- \hat{K} = estimativa do coeficiente Kappa;
- x_{ii} = valor na linha i e coluna i da matriz de erros;
- $x_{i\oplus}$ = total da linha i;
- $x_{\oplus i}$ = total da coluna i;
- n = número total de amostras; e
- c = número total de classes.

O coeficiente kappa é igual a zero quando o acerto obtido pelo classificador é igual ao acerto por acaso. Valores positivos de kappa ocorrem quando o acerto é maior que por acaso e negativos quando o acerto é pior do que uma classificação ao acaso. O maior valor de Kappa (+1,00) ocorre quando existe uma classificação perfeita (Cohen, 1960, citado ROSENFELD e FITZPATRICK-LINS, 1986).

VIEIRA (2000) utilizou um teste estatístico pareado para testar a significância dos classificadores utilizando os coeficientes Kappa. Os resultados foram sumarizados na forma de uma matriz de significância, em que os elementos da diagonal principal indicavam se o resultado da classificação é significativo (melhor do que o acaso). Na matriz de erros simples, o valor Z pode ser computado utilizando-se a equação 10 (VIEIRA, 2000):

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

em que Z é padronizado e normalmente distribuído e *var* é a variância para grandes amostras do coeficiente kappa. Essa variância pode ser determinada de acordo com a equação 11 (Bishop et al., 1975 citados por HUDSON e RAMM, 1987):

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

em que,

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

$$\theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i\oplus} x_{\oplus i}; \quad (13)$$

$$\theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_{ii} (x_{i\oplus} + x_{\oplus i}); \text{ e} \quad (14)$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_{ij} (x_{j\oplus} + x_{\oplus j})^2. \quad (15)$$

Se o Z calculado for maior que o valor crítico $Z_{\alpha/2}$ para um pré-determinado intervalo de confiança, a classificação é significativamente melhor que a classificação ao acaso. Os graus de liberdade são assumidos serem infinitos e $\alpha/2$ é o nível de confiança para o teste Z bilateral. Por outro lado, os elementos fora da diagonal fornecem uma indicação se os dois classificadores independentes são significativamente diferentes.

Para testar a significância entre dois coeficientes Kappa independentes a um determinado nível de significância, é utilizada a equação 16 (CONGALTON e MEAD, 1983):

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}} \quad (16)$$

Entretanto, STEHMAN (1992) chama a atenção que inferências estatísticas acerca de tabelas de contingência são baseadas em modelos de amostragem específicos. Cita Bishop et al. (1975) e Agresti (1989) e afirma que o erro padrão da estimativa do coeficiente Kappa é derivado assumindo-se amostragem multinomial. De acordo com STEHMAN (1992) são métodos usualmente empregados em sensoriamento remoto, uma vez que o modelo multinomial se aplica quando a amostragem aleatória estratificada é utilizada. Entretanto, as pressuposições das análises estatísticas podem ser violadas quando, por exemplo, os dados de referência forem obtidos com um delineamento de amostragem agrupado ou sistemático, pois as observações podem apresentar autocorrelação, sendo assim não independentes (Upton e Fingleton, 1989 citados por STEHMAN, 1992).

3. MATERIAL E MÉTODOS

3.1. Implantação e condução dos experimentos

Foram implantados dois experimentos, um com o trigo cultivado no campo e outro com o trigo cultivado em vasos. O experimento de campo foi realizado com o objetivo de coleta de imagens em condições de iluminação natural e o experimento com o trigo cultivado em vasos com o objetivo de obtenção de imagens em condições de iluminação controlada. Os experimentos foram implantados no campus da Universidade Federal de Viçosa, em Viçosa – MG. A cidade de Viçosa está localizada a uma altitude de aproximadamente 650m, com coordenadas geográficas de 20°45'54" latitude sul e 45°52'54" de longitude oeste.

Foi utilizada a cultivar BRS 207, que de acordo com a COMISSÃO DE PESQUISA DE TRIGO NO BRASIL-CENTRAL (2002), é indicada para semeadura no estado de Minas Gerais. Essa variedade é recomendada para cultivo com irrigação, em altitudes acima de 400 m, para solos com boa fertilidade e sem alumínio trocável.

O experimento de campo foi conduzido durante os meses de maio a setembro de 2004, sendo a semeadura realizada no dia 06/05/2004 e a colheita no dia 14/09/2004. Esse experimento constou de duas etapas distintas. Na primeira etapa, foram coletados dados para desenvolvimento e avaliação de classificadores, no intervalo entre a primeira e a segunda adubação em cobertura. Na segunda etapa, na colheita, coletaram-se dados para avaliação da resposta da cultura à adubação nitrogenada em cobertura. Foram implantadas 45 parcelas, sendo cada parcela constituída por seis linhas espaçadas 0,20 m e comprimento de 5,00 m, com área de 6,00 m². A área útil da parcela foi composta pelas quatro linhas centrais, eliminando-se 0,50 m de linha de cada lado para reduzir o efeito de bordadura. As adubações em cobertura foram realizadas a lanço nas entrelinhas da cultura, em duas épocas,

aos 15 e aos 35 dias após a emergência (DAE). Nas duas épocas foram utilizadas as doses correspondentes a 0, 30 e 60 kg de N.ha⁻¹, tendo como fonte o sulfato de amônio.

O experimento com o trigo cultivado em vasos foi conduzido durante os meses de julho e agosto de 2004. A semeadura foi realizada no dia 15 de julho e a emergência ocorreu no dia 19 de julho de 2004. Utilizaram-se 25 vasos de 14 litros e a adubação utilizada foi uniforme, com exceção da adubação nitrogenada.

No caso do experimento de campo, os classificadores foram elaborados para discriminar as três classes definidas pelas doses de N aplicadas em cobertura na primeira adubação. Sendo assim, na primeira etapa, utilizou-se delineamento inteiramente casualizado com três tratamentos e quinze repetições. Os tratamentos foram compostos pelas três doses de nitrogênio aplicados na primeira adubação em cobertura (0, 30 e 60 kg de N.ha⁻¹) aos 15 dias após a emergência da cultura.

Na segunda etapa do experimento de campo, para avaliação da resposta da cultura às doses de nitrogênio e ao parcelamento, foi utilizado um delineamento inteiramente casualizado com nove tratamentos e cinco repetições. Os tratamentos foram constituídos pela combinação de doses de nitrogênio em cobertura e duas formas de parcelamento. Os nove tratamentos são apresentados na Tabela 1.

TABELA 1. Tratamentos utilizados no experimento para avaliação da cultivar de trigo BRS 207 à adubação nitrogenada em cobertura e ao parcelamento

Tratamento	Primeira adubação em cobertura (kg N.ha ⁻¹)	Segunda adubação em cobertura (kg N.ha ⁻¹)
1	0	0
2	0	30
3	0	60
4	30	0
5	30	30
6	30	60
7	60	0
8	60	30
9	60	60

No caso do experimento em vasos foi utilizado um delineamento inteiramente casualizado com cinco tratamentos e cinco repetições. Cada parcela

foi composta por um vaso e os tratamentos consistiam de 5 doses de nitrogênio, correspondentes a 0, 30, 60, 90 e 120 kg de N.ha⁻¹.

Para o experimento de campo, a área foi preparada utilizando-se enxada rotativa e a adubação de plantio distribuída por meio de semeadora tracionada por trator. A adubação de plantio foi uniforme em todas as parcelas, na dose correspondente a 300 kg.ha⁻¹ do adubo formulado 8-28-16. A semeadura foi realizada no mês de maio de 2004, com semeadora manual, distribuindo-se as sementes no sulco onde foi aplicado o adubo. As sementes apresentavam 95% de germinação, e utilizou-se densidade de 70 sementes por metro linear, correspondendo a aproximadamente 370 sementes.m⁻². As plantas daninhas foram controladas 15 dias após a emergência da cultura (DAE) utilizando-se o herbicida Ally (5,0 g.ha⁻¹) associado a 2-4 D amina (0,5 L.ha⁻¹), pulverizados em área total. Foram realizadas duas aplicações do fungicida Folicur, na dose de 750 ml.ha⁻¹, uma aos 44 e outra aos 75 DAE.

No experimento em vasos, o solo foi peneirado e procedeu-se à mistura de calcário na dose de 9,5 g por vaso. O solo foi mantido úmido por 8 dias e em seguida procedeu-se à mistura dos adubos com o solo. Para cada vaso utilizou-se 12,1 g de super fosfato triplo, 5,6 g de superfosfato simples, 3,8 g de cloreto de potássio, 0,04 g de ácido bórico e 0,07g de sulfato de zinco. A semeadura foi realizada cinco dias após a mistura dos adubos ao solo, distribuindo-se 30 sementes por vaso. Dois dias após a emergência, procedeu-se à adubação nitrogenada utilizando uréia nas doses de 0; 0,48; 0,96; 1,44; e 1,92 g por vaso, correspondentes aos tratamentos 0, 30, 60, 90 e 120 kg de N.ha⁻¹, respectivamente. Os vasos foram mantidos em casa de vegetação até 18 DAE e em seguida transferidos para o exterior para desenvolvimento a sol pleno. Aos 10 e aos 18 DAE procedeu-se ao desbaste das plantas, retirando-se dez plantas em cada época, restando ao final dez plantas por vaso.

3.2. Desenvolvimento e avaliação de classificadores

Os classificadores foram desenvolvidos a partir de características extraídas de imagens digitais das plantas, estimativas do teor de clorofila nas folhas obtidas com um medidor de clorofila SPAD 502 e ainda com o teor total de N nas folhas obtido por meio de análise em laboratório. As imagens foram processadas para extração das características a serem utilizadas na classificação. No caso do

experimento de campo foram utilizados dois tipos de características obtidas nas imagens: características de reflectância e características de textura do dossel da cultura do trigo. No experimento em vasos utilizaram-se apenas características de reflectância. O critério de avaliação dos classificadores foi a exatidão na classificação. Os classificadores com características de imagens foram comparados aos classificadores com valores SPAD e N foliar. Outro fator avaliado foi a combinação de características obtidas a partir do processamento das imagens com mais de um índice e seu efeito na classificação das parcelas.

Aquisição de imagens digitais

Foi utilizada uma câmera digital Duncantech MS 3100, acoplada a um microcomputador por meio de uma placa de aquisição de vídeo National Instruments modelo PCI 1424. Utilizou-se uma lente com distância focal de 17mm. As imagens foram adquiridas utilizando-se o programa computacional Dtcontrol FG, fornecido pela empresa fabricante da câmera. As imagens foram salvas no formato TIFF (“tagged image file format”) com dimensões de 1392 (H) e 1039 (V) pixels.

A câmera utilizada permite a aquisição de imagens nas bandas do visível e no infravermelho próximo. Dessa forma, foram adquiridos simultaneamente dois tipos de imagens, coloridas e infravermelhas falsa cor. As imagens coloridas (RGB) são criadas pela composição das bandas do azul, verde e vermelho, ao passo que as imagens infravermelhas falsa cor (CIR) são criadas pela composição das bandas do infravermelho próximo, vermelho e verde.

A câmera Duncantech MS 3100 é equipada com três sensores do tipo CCD (“charge-coupled device”), os quais permitem o controle do ganho e do tempo de exposição em cada sensor individualmente. Um sensor é destinado à coleta da banda do vermelho, outro à coleta do infravermelho próximo e o terceiro à coleta das bandas verde e azul. A lente utilizada permitia o controle manual da abertura do diafragma, sendo que para obtenção de imagens no campo o “f-stop” foi definido em 5,6 e nas imagens dos vasos o “f-stop” foi definido em 3,5. Na Tabela 2 são apresentados o ganho e o tempo de exposição utilizados para cada sensor na aquisição das imagens no campo e na Tabela 3 o ganho e o tempo de exposição utilizados para cada sensor na aquisição das imagens dos vasos. A abertura do

diafragma, assim como o ganho e tempo de exposição foram definidos por tentativa, observando-se as imagens no monitor do computador.

TABELA 2: Ganho e o tempo de exposição para cada sensor para aquisição das imagens no campo

sensor	Vermelho	Infravermelho próximo	Verde e Azul
Ganho (dB)	8,6	9,7	6,0
Exposição (ms)	32,625	32,625	32,625

TABELA 3: Ganho e o tempo de exposição para cada sensor na aquisição das imagens dos vasos

sensor	Vermelho	Infravermelho próximo	Verde e Azul
Ganho (dB)	8,9	7,7	6,3
Exposição (ms)	113,500	113,500	99,375

No experimento de campo foram obtidas imagens das parcelas em três épocas: 23, 29 e 35 DAE, que correspondiam a 8, 14 e 20 dias após a primeira adubação em cobertura (DAA). Para obtenção das imagens no campo, a câmera foi posicionada 2,00 m verticalmente acima do solo, sobre as linhas centrais da parcela, evitando a obtenção de imagens da bordadura. Foram obtidas imagens de uma área de aproximadamente 0,70m por 0,50m, o que corresponde a uma resolução espacial de aproximadamente 0,05 cm.pixel⁻¹. Em cada uma das 45 parcelas foram obtidas três imagens, em posições diferentes, totalizando 135 imagens em cada época (8, 14 e 20 DAA). Nas três épocas, as imagens foram obtidas em condições de tempo encoberto (nublado) e aproximadamente no mesmo horário, a partir das 14h.

No experimento em vasos, as imagens foram obtidas em condições de iluminação controlada. Para tanto foi utilizada uma estrutura metálica com dimensão de 1,50 x 1,50m e 2,00m de altura recoberta com tecido do tipo “blackout” e um sistema de iluminação composto por oito refletores com lâmpadas halógenas de 150 watts. Os refletores foram direcionados para cima para evitar incidência de luz direta sobre as plantas. Os vasos foram posicionados individualmente no interior da estrutura para obtenção das imagens. Devido a problemas no sistema de aquisição de imagens, só foram obtidas imagens dos vasos aos 43 DAE.

Estimativas do teor de clorofila

No experimento de campo, as estimativas do teor de clorofila em cada parcela foram obtidas utilizando-se um medidor portátil de clorofila SPAD 502, nas mesmas épocas de obtenção das imagens. No experimento em vasos, foram obtidas leituras aos 15, 23, 27, 34 e 41 DAE.

Os valores medidos pelo equipamento (valores SPAD) correspondem à tonalidade de verde da folha da planta e representam uma medida indireta adimensional do teor de clorofila foliar (SCHEPERS et al., 1992). As folhas das plantas foram posicionadas entre o emissor e o receptor do equipamento de modo que a luz transmitida através da folha fosse convertida em sinais eletrônicos. Os valores são calculados com base na quantidade de luz transmitida pela folha na faixa do vermelho e do infravermelho próximo (SCHEPERS et al., 1996). O equipamento utilizado foi equipado com coletor de dados, com transferência posterior ao computador por meio de cabo serial.

No experimento de campo, em cada parcela foram obtidos 30 valores SPAD na folha mais nova completamente expandida de plantas diferentes ao longo de toda a parcela. No experimento em vasos, foram obtidas 20 leituras SPAD na folha mais nova completamente expandida das plantas de cada vaso.

Os valores considerados discrepantes, acima ou abaixo do valor médio \pm três vezes o desvio padrão foram eliminados. Esse tipo de valor discrepante pode ocorrer devido a um ajuste inadequado do equipamento à folha ou posicionamento do emissor sobre uma injúria provocada por inseto, por exemplo. A média dos valores não discrepantes foi considerada como o valor SPAD da parcela ou vaso em cada época.

Determinação do teor de nitrogênio foliar

O teor de N foliar foi utilizado para desenvolvimento de classificadores e para avaliação da correlação entre esses teores e os valores SPAD. Amostras de folhas foram coletadas nas parcelas do experimento de campo aos 21 DAA, no dia seguinte à coleta dos valores SPAD e obtenção das imagens, devido à impossibilidade de coleta no mesmo dia. De cada parcela foram coletadas 10 folhas mais novas completamente expandidas de plantas diferentes. Nas mesmas folhas, antes de serem destacadas das plantas, foi determinado o valor SPAD. No

experimento em vasos as plantas retiradas por ocasião dos desbastes, aos 10 e aos 18 DAE, e 10 folhas mais novas completamente expandidas aos 44 DAE de cada vaso foram utilizadas para determinação do teor de N.

O material coletado foi acondicionado em sacos de papel e enviado ao Laboratório de Solos Florestais do Departamento de Solos da Universidade Federal de Viçosa para determinação do teor total de N.

Avaliação da relação entre a dose de N em cobertura, valores SPAD e teor de nitrogênio foliar

Foi utilizada análise de regressão para verificar a existência de relação funcional entre as doses de N aplicadas na primeira adubação em cobertura e os valores SPAD, nas três épocas, e os valores de N foliar aos 21 DAA no campo. No experimento em vasos, avaliou-se a existência de relação entre as doses de N aplicadas e os valores SPAD aos 15, 23, 27, 34 e 41 DAE e os valores de N nas plantas aos 8 e aos 15 DAE e nas folhas aos 44 DAE.

Utilizando-se o programa computacional SAS efetuou-se o ajuste de um modelo linear simples aos dados e realizou-se o teste F para falta de ajustamento e análise de variância da regressão. Quando a falta de ajustamento foi significativa para o modelo linear simples procedeu-se ao ajuste de um modelo linear de segundo grau.

O relacionamento entre as variáveis N foliar e valores SPAD foi avaliado por meio de análise de regressão, tanto para os dados coletados no campo como para os dados oriundos do experimento em vasos.

Processamento das imagens

As imagens foram processadas utilizando-se o programa computacional Matlab, versão 6.5, e o pacote de ferramentas para processamento de imagens. O código fonte dos algoritmos é apresentado nos apêndices. As imagens originais apresentavam em suas bordas pixels com valores nulos. Dessa forma, foram eliminadas as 10 primeiras e as 10 últimas colunas de pixels das imagens, assim como as 10 primeiras e as 10 últimas linhas, reduzindo a dimensão das imagens processadas para 1372 (H) por 1019 (V) pixels. Das imagens originais foram separadas suas quatro bandas constituintes: infravermelho próximo, vermelho, verde

e azul. O processamento foi realizado utilizando-se nove índices espectrais, sendo quatro combinando as bandas do visível e cinco combinando bandas do visível e o infravermelho próximo, de acordo com as equações:

$$EVd = \frac{2 \cdot Vd - Vm - Az}{Vm + Vd + Az} \quad (17)$$

$$R_{VdVm} = \frac{Vd}{Vm} \quad (18)$$

$$Vdn = \frac{Vd}{Vm + Vd + Az} \quad (19)$$

$$Vmn = \frac{Vm}{Vm + Vd + Az} \quad (20)$$

$$NDVI = \frac{IV - Vm}{IV + Vm} \quad (21)$$

$$GNDVI = \frac{IV - Vd}{IV + Vd} \quad (22)$$

$$R_{Vd} = \frac{Vd}{IV} \quad (23)$$

$$R_{Vm} = \frac{Vm}{IV} \quad (24)$$

$$IVVd = \frac{IV + Vd - Vm - Az}{IV + Vm + Vd + Az} \quad (25)$$

em que,

- EVd = índice do excesso de verde;
- Vd = valor do pixel na banda do verde;
- Vm = valor do pixel na banda do vermelho;
- Az = valor do pixel na banda do azul;
- R_{VdVm} = razão verde-vermelho;
- Vdn = verde normalizado;
- Vmn = vermelho normalizado;
- $NDVI$ = índice de vegetação da diferença normalizado;
- IV = valor do pixel na banda do infravermelho próximo;
- $GNDVI$ = índice de vegetação da diferença de verde normalizado;
- R_{Vd} = razão verde - infravermelho;
- R_{Vm} = razão vermelho - infravermelho;
- $IVVd$ = índice do excesso de infravermelho e verde.

Dessa forma, a partir das imagens originais foram obtidas nove imagens índice. De cada imagem índice foram extraídas estimativas de reflectância e medidas de textura do dossel da cultura, no caso do experimento de campo. Para o experimento em vasos, utilizaram-se apenas estimativas de reflectância. Essas informações foram utilizadas para desenvolvimento de classificadores estatísticos.

A média dos valores dos pixels nas imagens índice foi considerada como uma estimativa da reflectância do dossel da cultura no experimento de campo. As imagens obtidas dos vasos apresentavam menor cobertura do solo em relação às imagens obtidas no campo. Para avaliar a influência do solo na classificação foram extraídos dois valores de reflectância de cada imagem índice: a média dos valores dos pixels e a média dos valores dos pixels representando folhas. Para obter a média dos valores dos pixels representando folhas utilizou-se a imagem obtida pelo processamento com o índice NDVI. A partir dessa imagem índice foi obtida uma imagem binária utilizando-se o método iterativo de limiarização citado por YANG et al. (2001). Nesse método o histograma da imagem é percorrido para encontrar o valor de limiar que promove o maior grau de separação entre as duas classes, assumindo-se que esse valor pode ser obtido calculando-se a média dos valores médios dos pixels nas duas classes de um histograma bimodal.

Os pixels em cada imagem índice que correspondiam aos pixels agrupados na classe de valor unitário na imagem binária foram considerados como representando folhas. A média desses pixels foi considerada a reflectância das folhas em cada imagem índice.

Como medidas de textura do dossel no campo, foram calculados cinco momentos do histograma (2º, 3º, 4º, 5º e 6º) de cada imagem índice, calculados de acordo com a equação 26 (GONZALES e WOODS, 1992).

$$\mu_n(z) = \sum_{i=1}^L (z_i - m)^n p(z_i) \quad (26)$$

em que,

- μ_n = n-ésimo momento de z em torno da média;
- m = valor médio de z;
- z = variável aleatória denotando a intensidade discreta da imagem; e
- $p(z_i)$ = densidade de z no nível de cinza i.

Segundo GONZALES e WOODS (1992), o segundo momento do histograma, representa a variância dos valores dos pixels; o terceiro momento é uma medida da assimetria e o quarto momento é uma medida da curtose do histograma. O quinto e o sexto momento, embora não relacionados ao formato do histograma, também fornecem informação quantitativa adicional para o conteúdo de textura.

Assim, para o experimento de campo, a partir de cada imagem índice foi extraído um vetor com características de reflectância e textura, para cada uma das 135 posições em que foram obtidas imagens no campo. Para reduzir o efeito de escala, as variáveis foram padronizadas de acordo com a equação 27 (JOHNSON e WICHERN, 1998).

$$z_p = \frac{z_i - m}{\sigma} \quad (27)$$

em que,

- z_p = valor da variável padronizada;
- z_i = valor da variável original;
- m = valor médio de z ; e
- σ = desvio padrão de z .

No caso do experimento em vasos, de cada imagem índice foram extraídos dois vetores com características de reflectância para cada um dos 25 vasos, um com a média de todos os pixels e outro com a média dos pixels representando folhas.

Desenvolvimento dos classificadores

Ainda utilizando-se o programa computacional Matlab, versão 6.5, foram desenvolvidos classificadores estatísticos (código fonte apresentado nos apêndices). Para o experimento de campo, foram utilizados para atribuir cada um dos 135 vetores a uma das três classes definidas pelas doses de N aplicadas em cobertura. No caso do experimento em vasos, o objetivo foi atribuir cada vetor a uma das cinco classes definidas pelas doses de N.

Assumindo-se que os dados apresentam distribuição normal e as probabilidades a priori de ocorrência das classes são iguais, um vetor desconhecido x foi atribuído à classe j que apresentou maior valor da função de decisão $d_j(x)$, a equação 5 pode ser reescrita da forma (GONZALES e WOODS, 1992).

$$d_j(x) = -0,5 \ln[\det(S_j)] - 0,5 [(x - m_j)^T \cdot S_j^{-1} (x - m_j)] \quad (28)$$

em que,

- x = vetor desconhecido a ser classificado;
- S_j = matriz de covariância da classe j ; e
- m_j = média da classe j .

Foram desenvolvidos classificadores utilizando apenas as características de reflectância, para todas as combinações dos nove índices espectrais, o que totalizou 511 combinações. As combinações são apresentadas na Tabela 4. Esse procedimento foi repetido para as três épocas de obtenção das imagens no caso do experimento de campo.

TABELA 4. Tipos de combinações de índices espectrais e número de classificadores desenvolvidos utilizando as médias dos valores dos pixels nas imagens índice.

Número de índices espectrais combinados	Número de classificadores
1	9
2	36
3	84
4	126
5	126
6	84
7	36
8	9
9	1
Total	511

De forma análoga, também foram desenvolvidos classificadores utilizando as médias e características de textura para combinações das nove imagens índice obtidas a partir das parcelas no campo. Quando se utilizaram as características de textura, o máximo de índices combinado foi seis, devido ao número de variáveis envolvidas (Tabela 5). Quando o número de amostras é menor ou igual ao número de variáveis o determinante da matriz de covariância é zero (JOHNSON e WICHERN, 1998). Uma vez que de cada imagem índice foram extraídas seis variáveis, a combinação de sete índices formaria um vetor com 42 variáveis. Como

havia 45 amostras de cada classe, na avaliação do classificador utilizando validação cruzada restariam apenas 44, o que poderia levar a obtenção de matrizes de variância mal condicionadas. Além disso, como ressaltado por KHATTREE e NAIK (2000), quanto maior o número de variáveis envolvidas na classificação maior a amostra necessária para obtenção dos mesmos níveis de precisão, de modo que para amostras pequenas o uso de grande número de variáveis não é recomendado.

TABELA 5. Tipos de combinações de índices espectrais e número de classificadores desenvolvidos utilizando as médias dos valores dos pixels e as características de textura nas imagens índice.

Número de índices espectrais combinados	Número de classificadores
1	9
2	36
3	84
4	126
5	126
6	84
Total	465

No experimento em vasos, como havia apenas cinco repetições e cinco tratamentos (doses de N) o máximo de combinações foi três (Tabela 6). O procedimento foi o mesmo, e desenvolvidos classificadores com a média dos valores dos pixels nas imagens índice e a média dos valores dos pixels representando folhas nas imagens índice.

TABELA 6. Tipos de combinações de índices espectrais e número de classificadores desenvolvidos utilizando as médias dos valores dos pixels nas imagens índice.

Número de índices espectrais combinados	Número de classificadores
1	9
2	36
3	84
Total	129

Os valores SPAD em cada parcela e nos vasos foram utilizados para desenvolver classificadores, um para cada época de obtenção dos dados. Os

valores de N nas plantas e nas folhas obtidos a partir da análise laboratorial também foram utilizados para o desenvolvimento de classificadores.

Avaliação dos classificadores

A fim de se obter uma estimativa não tendenciosa dos erros de classificação, utilizou-se a técnica de validação cruzada deixando uma amostra de fora. De acordo com JOHNSON e WICHERN (1998), nesse 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, e a taxa de erro na classificação é a proporção das amostras que foram classificadas incorretamente.

O resultado da classificação de cada combinação foi avaliado elaborando-se a matriz de erros e calculando-se a exatidão global e o coeficiente kappa. Segundo CONGALTON (1991), a matriz de erros é um arranjo quadrado em linhas e colunas e que expressa o número de amostras atribuídas às diferentes classes. As colunas usualmente representam os dados de referência enquanto as linhas indicam os resultados da classificação. CONGALTON (1991) sugere ainda que a técnica descritiva mais simples é a exatidão global, que pode ser computada dividindo-se o total de amostras corretamente classificadas (a diagonal da matriz de erros) pelo número total de amostras. A exatidão global foi calculada utilizando-se a equação:

$$EG = \frac{\sum_{i=1}^c x_{ii}}{n} \quad (29)$$

em que,

- EG = exatidão global da classificação;
- x_{ii} = valor na linha i e coluna i (diagonal) da matriz de erros;
- n = número total de amostras; e
- c = número total de classes.

ROSENFELD e FITZPATRICK-LINS (1986) citam Cohen (1960) que desenvolveu um coeficiente de concordância (denominado kappa) para escalas nominais. O coeficiente kappa leva em consideração toda a matriz de erros, incluindo os erros de classificação e indica o quanto o acerto do classificador é

melhor que o acerto por acaso. A equação 30 foi utilizada para estimativa do coeficiente kappa (HUDSON e RAMM, 1987).

$$\hat{K} = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}{n^2 - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}} \quad (30)$$

em que,

- \hat{K} = estimativa do coeficiente kappa;
- x_{ii} = valor na linha i e coluna i (diagonal) da matriz de erros;
- $x_{i\oplus}$ = total da linha i;
- $x_{\oplus i}$ = total da coluna i;
- n = número total de amostras; e
- c = número total de classes.

O coeficiente kappa é igual a zero quando o acerto obtido pelo classificador é igual ao acerto por acaso. Valores positivos de kappa ocorrem quando o acerto é maior que por acaso e negativos quando o acerto é pior do que uma classificação ao acaso. O maior valor de kappa (+1,00) ocorre quando existe uma classificação perfeita (Cohen, citado ROSENFELD e FITZPATRICK-LINS, 1986).

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 31 (CONGALTON e MEAD, 1983).

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}} \quad (31)$$

em que,

- Z = valor de Z calculado;
- \hat{K}_1 = coeficiente kappa do classificador 1;
- \hat{K}_2 = coeficiente kappa do classificador 2;
- $\text{var}(\hat{K}_1)$ = variância do coeficiente kappa do classificador 1; e
- $\text{var}(\hat{K}_2)$ = variância do coeficiente kappa do classificador 2.

A variância para grandes amostras do coeficiente kappa foi determinada de acordo com a equação 32 (Bishop et al., 1975 citados por HUDSON e RAMM, 1987).

$$\text{var}(\hat{K}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (32)$$

em que,

$$\theta_1 = \frac{1}{n} \sum_{i=1}^c x_{ii} ; \quad (33)$$

$$\theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i\oplus} x_{\oplus i} ; \quad (34)$$

$$\theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_{ii} (x_{i\oplus} + x_{\oplus i}) ; \quad (35)$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_{ij} (x_{j\oplus} + x_{\oplus j})^2 . \quad (36)$$

No experimento de campo foram realizados três tipos de comparação entre classificadores. Uma foi utilizada para comparar o resultado da classificação utilizando imagens, valores SPAD e teor de nitrogênio foliar. A segunda teve como objetivo comparar os classificadores com e sem a utilização de características de textura do dossel e a terceira foi realizada para avaliar a combinação de características extraídas das imagens índice.

No experimento em vasos, realizou-se a comparação entre os classificadores desenvolvidos com valores SPAD, N nas plantas e folhas e com as características de reflectância extraídas das imagens. Foram comparados ainda os classificadores desenvolvidos com as características de reflectância das imagens índice e os classificadores desenvolvidos com a reflectância das folhas.

Avaliação da classificação utilizando imagens, valores SPAD e teor de nitrogênio foliar

Em cada época de obtenção das imagens no campo, foi selecionado o melhor classificador. Foi escolhido aquele que apresentou o maior coeficiente kappa entre as 511 combinações dos vetores médios das características extraídas das três imagens de cada parcela. O coeficiente kappa do melhor classificador em cada época foi comparado por meio do teste Z ao nível de 5% de probabilidade com o resultado do classificador elaborado utilizando os valores SPAD na época correspondente. O classificador desenvolvido com os valores de N foliar das

amostras colhidas aos 21 DAA foi comparado por meio do mesmo teste, também a 5%, com os classificadores desenvolvidos a partir das imagens e valores SPAD aos 20 DAA.

No experimento em vasos, os resultado dos classificadores elaborados com os valores SPAD foram comparados com os classificadores desenvolvidos com os valores de N foliar também por meio do teste Z, ao nível de 5% de probabilidade, para épocas equivalentes. Os classificadores desenvolvidos a partir das imagens foram comparados ao classificador desenvolvido com valores SPAD aos 41 DAE e ao classificador com N foliar aos 44 DAE.

Os melhores classificadores com características das imagens e com valores SPAD de cada época foram comparados entre as épocas para avaliar a melhor época para identificação do estado nutricional por N e a classificação das plantas no experimento de campo. No experimento em vasos essa comparação foi realizada entre os classificadores desenvolvidos com valores SPAD e os desenvolvidos com N foliar.

Avaliação da utilização de características de textura do dossel no campo

Para avaliar a contribuição das características de textura do dossel na classificação das parcelas no campo, os coeficientes kappa dos melhores classificadores dos dois tipos, com e sem características de textura, foram comparados em cada época por meio do teste Z ao nível de 5% de probabilidade.

Avaliação da combinação de características das imagens índice

Nessa etapa, foram comparados os classificadores desenvolvidos com as diferentes combinações de características extraídas das imagens índice. Para os dados coletados no campo, essa comparação foi feita de acordo com a época (8, 14 e 20 DAA) e o tipo de característica utilizada na sua elaboração: características de reflectância (média dos pixels nas imagens índice) ou reflectância associada a características de textura (momentos do histograma das imagens índice). Para os dados coletados no experimento em vasos a comparação foi feita de acordo com a época.

Para cada situação, época e tipo de característica, os coeficientes kappa dos classificadores desenvolvidos foram comparados, por meio do teste Z com significância de 5%, ao coeficiente kappa do melhor classificador, selecionado pelo valor do coeficiente kappa. Os classificadores que proporcionaram valores do coeficiente kappa estatisticamente iguais ao melhor classificador em cada época e tipo de característica foram selecionados.

3.3. Avaliação da resposta da cultura à adubação nitrogenada em cobertura e parcelamento

O objetivo dessa etapa foi avaliar o efeito da aplicação de diferentes doses de N nas épocas tradicionalmente utilizadas para aplicação da adubação em cobertura na cultura do trigo. Essa informação é relevante para definição de estratégia para correção da deficiência de N durante o ciclo da cultura. A questão é: se a deficiência de N puder ser identificada antes da segunda adubação em cobertura, nas épocas tradicionalmente utilizadas na cultura do trigo, é possível corrigi-la sem prejuízo à produtividade?

Nessa etapa assumiu-se que a dose correta a ser aplicada em cobertura é de 60 kg de N.ha⁻¹ e que a segunda aplicação de N em cobertura seria realizada para complementar a dose aplicada na primeira adubação. A dose aplicada na primeira adubação será identificada por um classificador, a partir da resposta da cultura. Entretanto, a dose aplicada na segunda adubação pode ser incorreta devido aos erros de classificação.

Dessa forma, com os nove tratamentos utilizados, buscou-se avaliar os efeitos dos possíveis erros dos classificadores desenvolvidos com relação à altura de plantas, biomassa, produtividade, massa específica dos grãos e índice de colheita.

Altura de plantas

Essa é uma característica relevante na cultura do trigo, pois está relacionada com as perdas na colheita e tombamento de plantas (COELHO, 1997). Dez plantas por parcela útil, escolhidas aleatoriamente, foram medidas desde o nível do solo até o ápice da espiga, excluindo as aristas. Essa medição foi realizada imediatamente

antes da colheita das plantas. A média dos dez valores foi considerada a altura média das plantas em cada parcela.

Biomassa seca

No momento da colheita, as plantas da parcela útil foram ceifadas rente ao solo e determinou-se a massa total das parcelas. Foi utilizada uma balança digital Filizola com exatidão de 100 g. Em seguida, de cada parcela foi retirada uma amostra de 100 colmos com espiga. Entretanto, devido à capacidade da estufa disponível, a amostra foi reduzida para 30 colmos com espiga. Determinou-se então a massa fresca de cada amostra utilizando uma balança com exatidão de 0,01g. A amostra de 30 colmos foi a seguir submetida à secagem em estufa com circulação forçada de ar a 75° C por 48 horas (Sayre, 1993, citado por COELHO, 1997). Após a secagem, determinou-se a massa seca de cada amostra. A biomassa seca foi obtida por meio da equação:

$$B_s = \frac{\left(\frac{M_s}{M_f}\right) \cdot M_t}{A_p} \cdot 10000 \quad (37)$$

em que,

- B_s = Biomassa seca, kg.ha⁻¹;
- M_s = Massa seca da amostra, g;
- M_f = Massa fresca da amostra, g;
- M_t = Massa fresca total da parcela, kg; e
- A_p = Área da parcela útil, m².

Produtividade

As plantas colhidas na parcela útil, com exceção das 100 hastes selecionadas para determinação da biomassa seca, foram trilhadas mecanicamente. A massa dos grãos nas 100 hastes foi determinada à parte. A massa dos grãos trilhados mecanicamente e a massa dos grãos nas 100 hastes foram somadas para determinar a produção total das parcelas. As duas massas foram determinadas utilizando-se uma balança com exatidão de 0,01g.

Dos grãos trilhados mecanicamente de cada parcela foi retirada uma amostra e sua umidade foi determinada utilizando-se um medidor de umidade de cereais marca Gehaka modelo G800.

Trinta espigas das hastes utilizadas para determinação da umidade e cálculo da biomassa seca foram debulhadas manualmente e a massa dos grãos determinada. Uma amostra dos grãos debulhados foi submetida à secagem em estufa a 105° C por 24 horas para determinação da umidade.

As massas de grãos, provenientes das parcelas e da amostra de 30 hastes, foram corrigidas para a umidade de 13% em base úmida por meio da equação:

$$MG_{13\%} = \left(\frac{MGu_i \cdot (1 - u_i)}{1 - 0,13} \right) \quad (38)$$

em que,

$MG_{13\%}$ = Massa de grãos com 13% de umidade, g;

MGu_i = Massa de grãos na umidade inicial, g;

u_i = Umidade inicial, decimal.

Uma vez que foram retiradas 100 hastes de cada parcela, a massa de grãos proveniente da amostra de 30 hastes foi corrigida utilizando-se a equação:

$$M_{100} = \frac{M_{30}}{3} \cdot 10 \quad (39)$$

em que,

M_{100} = Massa de grãos de 100 hastes com 13% de umidade, g; e

M_{30} = Massa de grãos de 30 hastes com 13% de umidade, g

A produtividade das parcelas foi calculada por meio da equação:

$$P_{13\%} = \frac{MTg}{Ap} \cdot 10 \quad (40)$$

em que,

$P_{13\%}$ = Produtividade com 13% de umidade, kg.ha⁻¹;

MTg = Massa total de grãos à umidade de 13%, g; e

Ap = Área da parcela útil, m².

Massa específica

Da produção de cada parcela foram retiradas amostras, que foram mantidas em um secador com temperatura de 40° C até que atingissem a umidade de 13 ± 1%. Foi utilizada uma balança Dallemole tipo 40 para determinação de peso hectolítrico. A massa de grãos proveniente de cada amostra, que preencheu o recipiente com capacidade de ¼ de litro, foi determinada em uma balança eletrônica

com sensibilidade de 0,01g. Em seguida, os valores foram corrigidos para a massa correspondente a um volume de 100 L.

Índice de colheita

O índice de colheita é uma medida da produção de grãos pela cultura em relação à biomassa total. De modo geral, quando ocorre um crescimento vegetativo exagerado pode ocorrer autossombreamento e acamamento, o que diminui a interceptação de energia luminosa, fotossíntese líquida e produção de assimilados (COELHO, 1997), com prejuízo à produção de grãos.

A massa total de grãos produzida nas parcelas foi corrigida para 0% de umidade por meio da equação:

$$MG_{0\%} = MG_{u_i} \cdot (1 - u_i) \quad (41)$$

em que,

$MG_{0\%}$ = Massa de grãos com 0% de umidade, g;

MG_{u_i} = Massa total de grãos à umidade inicial, g;

A partir desses valores calculou-se a produtividade das parcelas com 0% de umidade. O índice de colheita foi determinado por meio da equação:

$$IC = \frac{P_{0\%}}{BS} \quad (42)$$

em que,

IC = Índice de colheita;

$P_{0\%}$ = Produtividade com 0% de umidade, kg.ha⁻¹;

BS = Biomassa seca, kg/ha;

Análise estatística

Os dados coletados nessa etapa foram submetidos à análise de variância e ao teste de Tukey com nível de significância de 5% utilizando-se o programa computacional SAS.

4. RESULTADOS E DISCUSSÃO

4.1. Etapa de desenvolvimento e avaliação de classificadores

Avaliação da relação entre a dose de N em cobertura e valores SPAD no campo

A evolução dos valores SPAD para as três doses de N aplicadas em cobertura é ilustrado na Figura 2.




Figura 2. Valores SPAD médios observados nas parcelas de trigo cultivado no campo aos 8, 14 e 20 DAA para as doses 0, 30 e 60 kg de N.ha⁻¹ aplicadas em cobertura.

Houve redução dos valores SPAD dos oito aos 14 DAA nas três doses de N utilizadas. Acredita-se que a redução nos valores SPAD de 8 para 14 DAA ocorreu devido ao desenvolvimento das plantas, visto que a redução também foi observada nas parcelas não adubadas. As doses de N aparentemente influenciaram o decréscimo nos valores SPAD, uma vez que esse comportamento foi mais acentuado na dose 30 que na dose 60 kg de N.ha⁻¹ e o maior decréscimo foi verificado nas parcelas não adubadas. Nas parcelas adubadas houve tendência de

aumento nos valores SPAD aos 20 DAA, o que não se verificou nas parcelas não adubadas. A variação nos valores SPAD durante o desenvolvimento da cultura, mesmo em plantas adequadamente nutridas, também foi verificada por outros autores, como por exemplo SCHEPERS et al. (1992). No intuito de compensar essa variação, entre outros fatores, esses autores sugerem a utilização de uma parcela de referência adequadamente nutrida para comparação com o restante da cultura.

Os resultados da análise de variância do teste F para falta de ajustamento dos modelos lineares de primeiro grau ajustados para 8, 14 e 20 DAA são apresentados nas Tabelas 7, 8 e 9, respectivamente.

TABELA 7. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N em cobertura e valores SPAD aos oito DAA

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	29,661	29,6610	16,6809	0.0002
Falta de ajustamento (Tratamentos)	1	5,9547	5,9547	3,3488	0,0744
Resíduo	2	35,6157			
Total	42	74,6817	1,7781		
Total	44	110,2974			

TABELA 8. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N em cobertura e valores SPAD aos 14 DAA

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	139,7139			
Falta de ajustamento (Tratamentos)	1	10,9065	10,9065	4,8261	0,0371
Resíduo	2	150,6204			
Total	26	58,7567	2,2599		
Total	28	209,3772			

TABELA 9. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N em cobertura e valores SPAD aos 20 DAA

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	238,1586			
Falta de ajustamento (Tratamentos)	1	18,6899	18,6899	9,5328	0,0036
Resíduo	2	256,8485			
Total	42	82,3445	1,9606		
Total	44	339,1930			

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 simples obtido com os valores SPAD determinados aos oito DAA. Entretanto, com os valores aos 14 e aos 20 DAA a hipótese foi rejeitada, ou seja, o modelo adotado não se ajusta bem aos dados. Na época 14 DAA o número total de graus de liberdade foi apenas 28, porque o número de valores SPAD foi menor, devido à irrigação de experimento vizinho, que provocou umedecimento das folhas das plantas em algumas parcelas, impossibilitando a coleta dos valores SPAD.

Uma vez que o teste F para falta de ajustamento não foi significativo para os valores SPAD coletados aos oito DAA, a regressão obtida foi submetida à análise de variância. No caso da análise de variância da regressão, a hipótese H0 é a de que os coeficientes da regressão são iguais a zero, ou seja, a variável independente não exerce influência na variável dependente, segundo o modelo proposto (RIBEIRO JÚNIOR e SANTOS, 2004). No caso da época oito DAA o teste F da regressão foi significativo, rejeitando-se a hipótese H0.

Os valores SPAD para a época oito DAA e o modelo ajustado são apresentados na Figura 3.




Figura 3. Valores SPAD, 8 dias após a adubação em cobertura, para o cultivar de trigo BRS 207 cultivado no campo, sob três doses de adubação nitrogenada em cobertura.

O fato do modelo linear se ajustar na época inicial (oito DAA), embora apresentando R² baixo (0,27), talvez possa ser explicado pela necessidade de pelo menos três semanas após a adubação para a completa resposta em termos de clorofila na cultura do trigo (MURDOCK et al., 1997). Dessa forma, é provável que na

época oito DAA a resposta das plantas às doses de N em termos de clorofila foliar ainda não fossem evidentes.

Uma vez que o modelo linear não se ajustou aos valores SPAD nas épocas 14 e 20 DAA procedeu-se ao ajuste de um modelo linear de segundo grau. Devido ao número de tratamentos (doses de N) não foi possível a realização do teste F para falta de ajustamento para esses modelos. Os quadros de análise de variância do teste F para os modelos lineares de segundo grau ajustados são apresentados nas Tabelas 10 e 11, respectivamente.

TABELA 10. Análise de variância do teste F para o modelo linear de segundo grau entre doses de N em cobertura e valores SPAD aos 14 DAA

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	2	150,6204	75,3102	33,32	< 0,0001
Resíduo	26	58,7567	2,2599		
Total	28	209,3772			

TABELA 11. Análise de variância do teste F para o modelo linear de segundo grau entre doses de N em cobertura e valores SPAD aos 20 DAA

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	2	256,8485	128,4242	65,50	< 0,0001
Resíduo	42	82,3445	1,9606		
Total	44	339,1930			

Os valores SPAD observados e os modelos ajustados para as épocas 14 e 20 DAA são ilustrados nas Figuras 4 e 5, respectivamente.

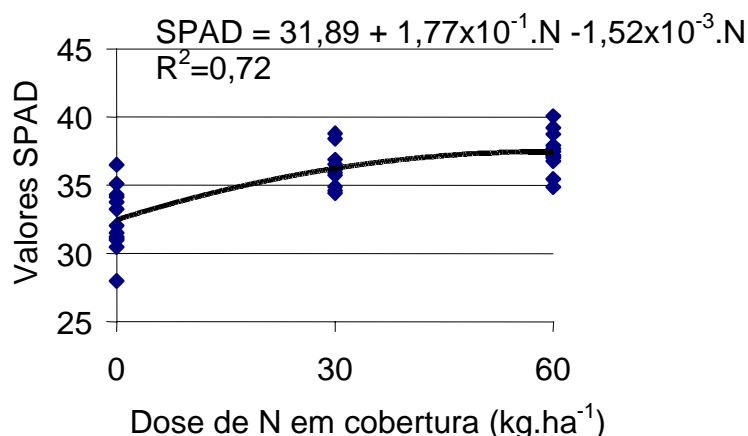


Figura 4. Valores SPAD, 14 dias após a adubação em cobertura, para o cultivar de trigo BRS 207 cultivado no campo sob três doses de adubação nitrogenada em cobertura.




Figura 5. Valores SPAD, 20 dias após a adubação em cobertura, para o cultivar de trigo BRS 207 cultivado no campo sob três doses de adubação nitrogenada em cobertura.

Embora o teste para falta de ajustamento dos modelos lineares de segundo grau não ter sido realizado, dados da literatura (SCHEPERS et al., 1992; SCHRODER et al., 2000; LAVRES JUNIOR, 2002) indicam que os valores SPAD tendem a se estabilizar em doses elevadas de N. Além disso, a dose de 60 kg de N.ha⁻¹ em cobertura é próxima à dose indicada para a cultura do trigo nas condições em que foi cultivado (COELHO, 1997; SOUZA e FRONZA, 1999). Isso leva a crer que a cultura já estava atingindo o ponto de produção máxima ou região de adequação, com reflexo nos valores SPAD (Figuras 4 e 5), pois quando a disponibilidade de N se aproxima do nível crítico, o teor de clorofila foliar tende a se estabilizar (SCHEPERS et al., 1998).

A curva de relação entre o crescimento e produção das culturas e o teor de nutriente em seus tecidos apresenta regiões distintas. Na região denominada de deficiência o aumento no suprimento do nutriente limitante é acompanhado pelo aumento de seu teor nos tecidos. Na região de adequação, o aumento do suprimento do nutriente e seu teor nos tecidos não são acompanhados por aumento no crescimento ou produção. A região de toxidez caracteriza-se por decréscimo no crescimento ou produção com o aumento do suprimento de um dado nutriente e seu teor nos tecidos (MARTINEZ et al., 1999). Esses autores destacam ainda que o nível crítico é o teor de um determinado nutriente que se associa a 90% da produtividade ou crescimento máximos. Caso a concentração esteja abaixo do nível crítico, considera-se que a planta pode apresentar problemas nutricionais com relação àquele nutriente.

Avaliação da relação entre a dose de N e valores SPAD no trigo cultivado em vasos

A evolução dos valores SPAD para as doses de N aplicadas no trigo cultivado em vasos é apresentado na Figura 6.

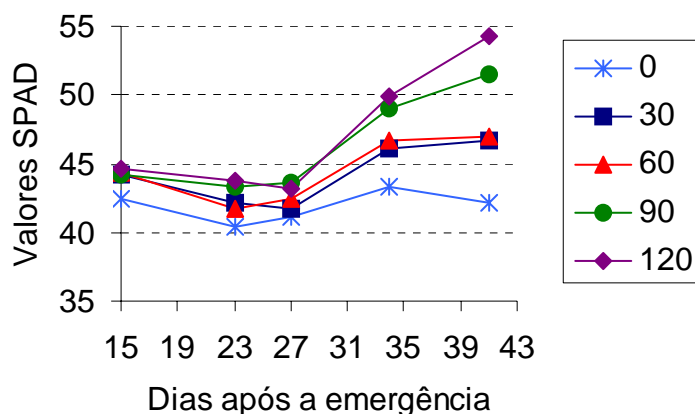


Figura 6. Valores SPAD aos 15, 23, 27, 34 e 41 DAE para as doses de 0, 30, 60, 90 e 120 kg de N.ha⁻¹ para o trigo cultivado em vasos.

No trigo cultivado em vasos e com a adubação nitrogenada realizada na emergência das plantas verificou-se um comportamento semelhante ao observado no campo. A obtenção dos valores SPAD foi realizada a partir do perfilhamento. Houve um decréscimo nos valores SPAD na fase inicial e posterior aumento nos valores. Entretanto, mesmo nas plantas não adubadas ocorreu um aumento após os 23 DAE. Verificou-se um aumento mais acentuado nos valores nos vasos com doses mais elevadas e estabilização dos valores SPAD nas doses de 30 e 60 kg de N.ha⁻¹ após os 34 DAE. Essa estabilização entretanto não foi verificada nas doses 90 e 120 kg de N.ha⁻¹.

A análise de variância do teste F para falta de ajustamento para os modelos lineares de primeiro grau ajustados entre as doses de N e os valores SPAD aos 15, 23, 27, 34 e 41 DAE são apresentados nas Tabelas 12, 13, 14, 15 e 16, respectivamente.

TABELA 12. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N e valores SPAD aos 15 dias após a emergência (DAE)

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	9,2536	9,2536	15,42	0,0008
Falta de ajustamento (Tratamentos)	3	4,6596	1,5532	2,59	0,0816
Resíduo	4	13,9132			
	20	12,0059	0,6003		
Total	24	25,9191			

TABELA 13. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N e valores SPAD aos 23 dias após a emergência (DAE)

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	31,6013	31,6013	30,60	< 0,0001
Falta de ajustamento (Tratamentos)	3	4,6672	1,5557	1,51	0,2434
Resíduo	4	36,2684			
	20	20,6562	1,0328		
Total	24	56,9246			

TABELA 14. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N e valores SPAD aos 27 dias após a emergência (DAE)

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	17,4404	17,4404	29,78	< 0,0001
Falta de ajustamento (Tratamentos)	3	2,5875	0,8625	1,47	0,2522
Resíduo	4	20,0279			
	20	11,7148	0,5857		
Total	24	31,7427			

TABELA 15. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N e valores SPAD aos 34 dias após a emergência (DAE)

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	129,8627	129,8627	41,22	< 0,0001
Falta de ajustamento (Tratamentos)	3	5,2755	1,7585	0,56	0,6487
Resíduo	4	135,1382			
	20	63,0090	3,1504		
Total	24	31,7427			

TABELA 16. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N e valores SPAD aos 41 dias após a emergência (DAE)

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	421,3124	421,3124	63,85	< 0,0001
Falta de ajustamento (Tratamentos)	3	18,2602	6,0867	0,92	0,4480
Resíduo	4	439,5726			
Total	20	131,9598	6,5980		
	24	571,5324			

Uma vez que a falta de ajuste não foi significativa para os modelos lineares em todas as épocas procedeu-se ao ajuste desse modelo. Para as cinco épocas de obtenção dos valores SPAD a regressão foi significativa. Os modelos ajustados, assim como seus coeficientes de determinação são apresentados na Tabela 17.

TABELA 17. Modelos lineares simples ajustados entre as doses de N e os valores SPAD aos 15, 23, 27, 34 e 41 DAE e seus coeficientes de determinação.

Dias após a emergência	Modelo	Coefficiente de determinação
15	$SPAD = 43,08 + 1,43 \times 10^{-2} \cdot N$	0,36
23	$SPAD = 40,68 + 2,65 \times 10^{-2} \cdot N$	0,55
27	$SPAD = 41,24 + 1,97 \times 10^{-2} \cdot N$	0,55
34	$SPAD = 43,76 + 5,37 \times 10^{-2} \cdot N$	0,65
41	$SPAD = 42,48 + 9,68 \times 10^{-2} \cdot N$	0,74

Verifica-se que embora as regressões tenham sido significativas em todas as épocas, o coeficiente de determinação foi maior com o avanço da idade. Embora os valores do intercepto tenham sido semelhantes, refletiram a variação nos valores SPAD durante o desenvolvimento da cultura (Figura 6), uma vez que representam o valor SPAD estimado de uma planta de trigo sem adubação nitrogenada em cobertura. Verificou-se ainda que com o desenvolvimento, a influência da dose de N sobre os valores SPAD se intensificou, de acordo com a inclinação da reta ajustada.

Os modelos ajustados para as épocas 23, 27, 34 e 41 DAE no experimento com o trigo cultivado em vasos são ilustrados na Figura 7.

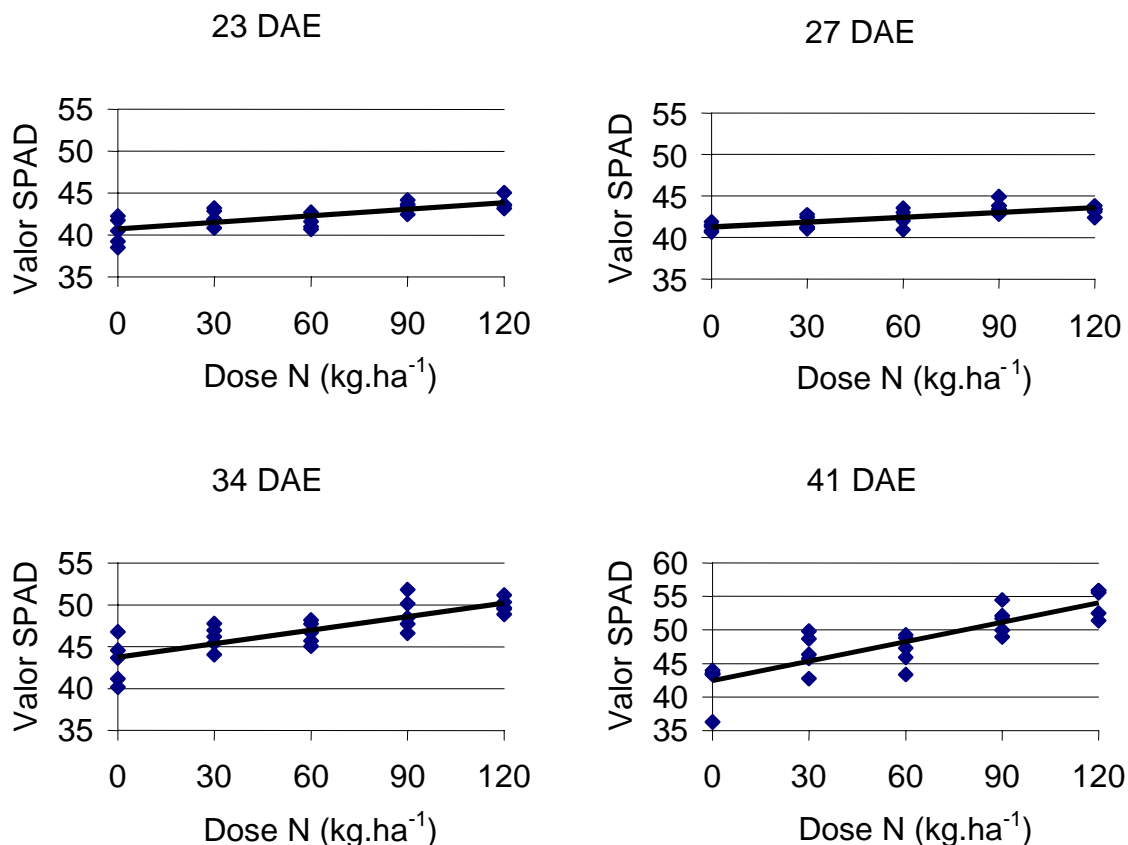


Figura 7. Valores SPAD observados e modelos lineares simples ajustados aos 23, 27, 34 e 41 DAE no experimento com o trigo cultivado em vasos para as cinco doses de nitrogênio.

No cultivo em vasos não houve a estabilização dos valores SPAD em doses próximas a 60 kg de N.ha⁻¹, conforme observado no campo. Deve-se destacar entretanto que no experimento em vasos, a dose de fósforo utilizada foi mais elevada, devido ao desenvolvimento radicular peculiar que ocorre nesse tipo de cultivo em vasos. De acordo com DIAS et al. (1996), a obtenção de resposta positiva à adubação nitrogenada na maioria dos solos brasileiros só é observada quando a limitação do fósforo disponível é parcial ou totalmente corrigida. Como não havia limitação de fósforo, acredita-se que a região de adequação iria ocorrer em doses mais elevadas de N. Dessa forma, a estabilização dos valores SPAD em torno de 60 kg de N.ha⁻¹ no campo talvez possa ser explicada pela menor disponibilidade de fósforo. LOPEZ-BELLIDO et al. (2004), em trabalho com trigo na Inglaterra, observaram incrementos crescentes na produtividade até doses de 300 kg de N.ha⁻¹, e comportamento semelhante para os valores SPAD.

Nitrogênio foliar no experimento de campo

A análise de variância do teste F para falta de ajustamento do modelo entre doses de N em cobertura e teores de N foliar do trigo cultivado no campo aos 21 DAA é apresentada na Tabela 18 .

TABELA 18. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N em cobertura e teores de N foliar aos 21 DAA

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	14,3853	14,3853	135,0679	< 0,0001
Falta de ajustamento (Tratamentos)	1	0,3517	0,3517	3,3021	0,0763
Resíduo	42	4,4732	0,1065		
Total	44	19,2102			

A falta de ajustamento não foi significativa, o que permitiu a análise de variância da regressão, que por sua vez foi significativa a 5% de probabilidade. O comportamento dos valores de N foliar em relação às doses de N utilizadas e o modelo ajustado são ilustrados na Figura 8.




Figura 8. Valores de N foliar, 21 dias após a adubação em cobertura, para o cultivar de trigo BRS 207 cultivado no campo sob três doses de adubação nitrogenada em cobertura.

Da mesma forma que os valores SPAD, que representam a clorofila foliar, o teor de N foliar tende a aumentar com o aumento da disponibilidade no solo, até atingir a região de adequação. Além desse ponto, o incremento nos teores foliares com o aumento da disponibilidade diminui, mas de forma menos acentuada que os teores de clorofila (SCHEPERS et al., 1996). Um dos motivos é que o nitrogênio não

utilizado pela planta na síntese de compostos orgânicos, entre eles a clorofila, pode ser acumulado nas folhas na forma de nitrato. O ajuste do modelo linear aos valores de N foliar, com coeficiente de determinação de 0,69, e a falta de ajustamento do mesmo modelo aos valores SPAD na mesma época é mais uma indicação que, embora os teores foliares de N atinjam um platô em doses mais elevadas, isso ocorre de forma menos acentuada que no teor de clorofila.

O comportamento dos valores SPAD em relação à disponibilidade de N deve ser considerada ao se utilizar o medidor de clorofila SPAD 502. Suas leituras não são afetadas pelo excesso de N disponível, o que é uma característica importante quando se deseja relacionar suas leituras com a produtividade (SCHEPERS, 1998). Por outro lado, se o objetivo é identificar disponibilidade excessiva de N no solo, torna-se uma limitação, assim como o teor de N foliar (SCHRÖDER et al., 2000).

Nitrogênio foliar no experimento em vasos

A análise de variância do teste F para falta de ajustamento dos modelos lineares simples entre as cinco doses de N e os teores de N nas plantas de trigo cultivadas em vasos aos 10, 18 e 44 DAE são apresentadas nas Tabelas 19, 20 e 21, respectivamente.

TABELA 19. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N em cobertura e teores de N nas plantas de trigo cultivadas em vasos aos 10 DAE

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	0,0536	0,0536	1,90	0,1835
Falta de ajustamento (Tratamentos)	3	0,0069	0,0023	0,08	0,9691
Resíduo	4	0,0605			
Total	20	0,5648	0,0282		
	24	0,6253			

TABELA 20. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N em cobertura e teores de N nas plantas de trigo cultivadas em vasos aos 18 DAE

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	0,4207	0,4207	13,32	0,0017
Falta de ajustamento (Tratamentos)	3	0,0162	0,0054	0,17	0,9149
Resíduo	4	0,4368			
Total	19	0,6000	0,0316		
	23	1,0368			

TABELA 21. Análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre doses de N em cobertura e teores de N nas plantas de trigo cultivadas em vasos aos 44 DAE

Fator de Variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Regressão	1	8,1842	8,1842	61,66	<0,0001
Falta de ajustamento (Tratamentos)	3	0,1467	0,0489	0,37	0,7766
Resíduo	4	8,3310			
Total	20	2,6547	0,1327		
	24	10,9857			

O modelo linear simples ajustou-se aos dados de N aos 10 DAE, uma vez que o teste para falta de ajustamento não foi significativo a 5% de probabilidade. Dessa forma, procedeu-se ao ajuste do modelo aos dados, cujo teste F indicou que a regressão não foi significativa. Isso indica que aos 10 DAE o teor de N nas plantas não foi influenciado pela doses de nitrogênio, segundo o modelo proposto.

Na época 18 DAE os graus de liberdade total foram reduzidos para 23 devido à exclusão de uma amostra proveniente de um vaso submetido à dose 120 kg de N.ha⁻¹ que apresentou valor discrepante. Aos 18 e aos 44 DAE a falta de ajustamento do modelo linear simples não foi significativa a 5% de probabilidade, o que permitiu o ajuste dos modelos. As regressões foram significativas a 5% de probabilidade, indicando que as doses de N influenciaram os teores de N nas plantas, aos 18 e nas folhas aos 44 DAE, segundo o modelo linear simples.

Os valores observados e os modelos ajustados para as épocas 18 e 44 DAE são apresentados nas Figuras 9 e 10, respectivamente.

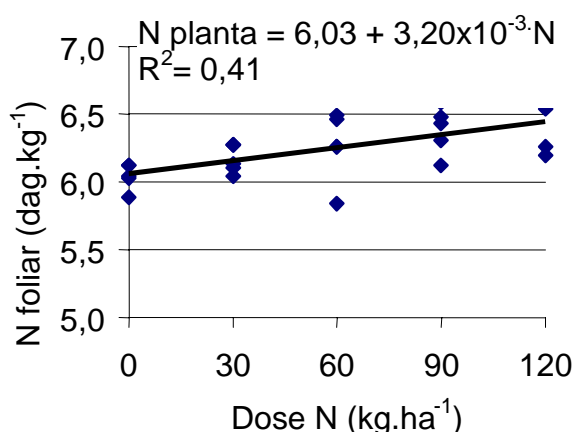


Figura 9. Valores de N foliar e modelo ajustado, 18 dias após a emergência, para o cultivar de trigo BRS 207 cultivado em vasos sob cinco doses de adubação nitrogenada.

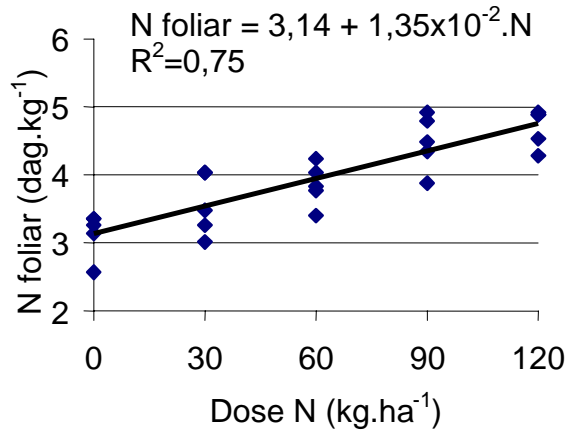


Figura 10. Valores de N foliar e modelo ajustado, 44 dias após a emergência, para o cultivar de trigo BRS 207 cultivado em vasos sob cinco doses de adubação nitrogenada.

Verifica-se que o coeficiente da regressão para a época 44 DAE foi maior que na época 18 DAE. Isso indica que com o desenvolvimento das plantas a variação do teor de N nas plantas apresenta maior incremento para cada unidade de nitrogênio aplicado. Além disso verificou-se que o comportamento dos valores de N nas folhas e nas plantas foi semelhante ao verificado para os valores SPAD nos vasos. Houve uma tendência linear e crescente de aumento nos valores SPAD e de N foliar com o aumento da dose. No experimento no campo, por outro lado, embora os valores de N foliar apresentassem tendência semelhante, houve a estabilização dos valores SPAD próximo da dose 60 kg de N.ha⁻¹. Isso parece indicar que nos vasos, com as doses utilizadas, não se atingiu o ponto onde há a estabilização dos teores de clorofila e o N passa a ser acumulado nas folhas em outras formas. Acredita-se que esse comportamento pode ter ocorrido devido às doses de fósforo mais elevadas no experimento em vasos, que não limitou a utilização do N.

Relação entre N foliar e valores SPAD no experimento de campo

Os coeficientes de correlação entre os valores SPAD e os teores de N foliar para as três doses de N aplicadas em cobertura no campo são apresentados na Tabela 22.

TABELA 22. Coeficientes de correlação entre os valores SPAD e os teores de N foliar para três doses de N aplicadas em cobertura aos 21 DAA

Dose (kg.ha ⁻¹)	Correlação	Pr > F
0	0,7637	0,0009
30	0,6603	0,0074
60	-0,0694	0,8060
Total	0,8970	< 0,0001

A correlação entre os valores SPAD e os teores de N foliar decresceu com o aumento da dose. Na dose de 60 kg.ha⁻¹ a correlação não foi significativa. Isso reforça a hipótese de que essa dose mais alta propicia o consumo de luxo, ou seja, a ausência de correlação indica que, nas condições em que foram cultivadas, nessa dose as plantas de trigo não apresentavam deficiência de N. Verifica-se que na dose zero, onde as plantas certamente estavam na fase de deficiência da curva de resposta ao N, foi a dose onde se verificou a maior correlação.

O modelo linear simples ajustado entre os valores SPAD e os valores de N foliar aos 21 dias após a adubação é apresentado na Figura 11.




Figura 11. Modelo linear ajustado entre os valores de N foliar e os valores SPAD cultivar de trigo BRS 207, 21 DAA sob três níveis de N em cobertura (0, 30 e 60 kg N.ha⁻¹).

De acordo com HOFFMAN e VIEIRA (1983), para se proceder à análise de regressão de um modelo linear simples em que as duas variáveis (X e Y) são aleatórias, devem ser verdadeiras as pressuposições:

- a relação entre X e Y é linear;
- a média do erro é nula;

- para um dado valor de X a variância residual é sempre σ^2 , ou seja, o erro é homocedástico;
- o erro de uma observação é não correlacionado com o erro em outra observação; e
- os erros têm distribuição normal

Além disso, HOFFMAN e VIEIRA (1983) ressaltam que se deve pressupor ainda que os erros são independentes dos valores de X. Dessa forma, considerando-se as distribuições condicionais da variável Y ou dos erros para cada X, pode-se verificar se os resultados obtidos são válidos. Entretanto, devido ao número de observações, nesse trabalho, nem todas as pressuposições citadas podem ser verificadas. Sendo assim, o modelo apresentado deve ser utilizado apenas como uma forma de avaliar a relação entre as variáveis aleatórias estudadas, valores SPAD e N foliar.

Testou-se ainda o ajuste de um modelo não linear exponencial aos mesmos dados, apresentado na Figura 12.

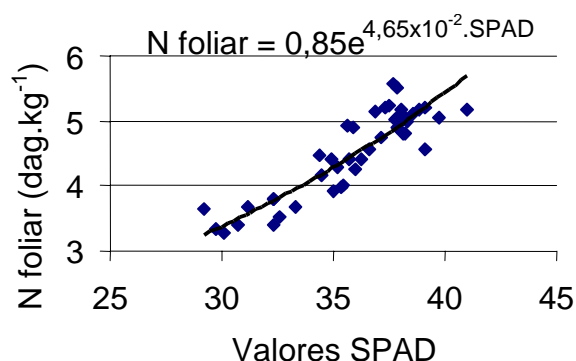


Figura 12. Modelo exponencial ajustado entre os valores de N foliar e os valores SPAD em trigo cultivar BRS 207, 21 DAA sob três níveis de N em cobertura (0, 30 e 60 kg N.ha⁻¹).

De acordo com Souza (1998), citado por REGAZZI (2000), no caso do modelo de regressão não linear, o ajustamento pode ser medido pelo quadrado do coeficiente de correlação entre os valores observados e preditos. Por outro lado, REGAZZI (2000) cita Ratkowsky (1990) que afirma que o R^2 não tem nenhum significado óbvio para um modelo de regressão não linear e não precisa ser calculado. REGAZZI (2000) ressalta que no caso do modelo não linear o R^2 não deve ser interpretado da mesma forma que no caso do modelo de regressão linear com intercepto, pois, para a regressão não linear o R^2 pode ser alto e mesmo

assim, haver uma grande discrepância entre os valores observados e preditos. Dessa maneira, optou-se pela comparação entre os erros médios absolutos e visualização resíduos para comparação entre o modelo linear e não linear.

Os resíduos do ajuste do modelo linear são apresentados na Figura 13 e do modelo exponencial na Figura 14. O modelo linear apresentou um erro absoluto médio de 4,95% enquanto o modelo exponencial apresentou um erro absoluto médio de 4,93%. Uma vez que os resultados dos dois modelos foram semelhantes, em termos de erro absoluto médio e distribuição dos resíduos, o modelo linear foi escolhido, devido à sua simplicidade.

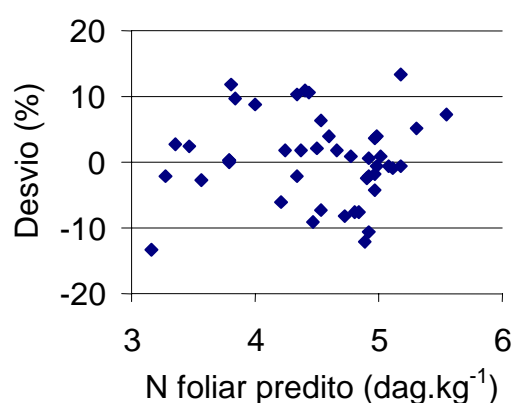


Figura 13. Resíduos do ajuste do modelo linear entre os valores de N foliar e os valores SPAD em trigo, cultivar BRS 207, 21 DAA sob três níveis de N em cobertura (0, 30 e 60 kg N.ha⁻¹).

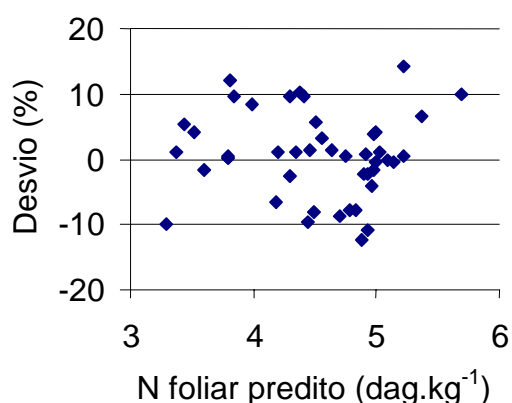


Figura 14. Resíduos do ajuste do modelo exponencial entre os valores de N foliar e os valores SPAD em trigo, cultivar BRS 207, 21 DAA sob três níveis de N em cobertura (0, 30 e 60 kg N.ha⁻¹).

Outros trabalhos indicam um relacionamento linear entre valores SPAD e N foliar. LOPEZ-BELLIDO et al. (2004) trabalharam com o mesmo cultivar de trigo na

Inglaterra, durante oito estações, e observaram relacionamento linear entre os valores SPAD e a porcentagem de N nas folhas na antese. O modelo linear ajustado apresentou um coeficiente de determinação de 0,94. Estes autores observaram valores SPAD na folha bandeira na antese variando de 33,5 na dose zero até um platô em torno de 50 na dose 250 kg de N.ha⁻¹. Entretanto, as leituras foram realizadas na antese, um estágio mais avançado da cultura em relação ao presente trabalho. O relacionamento linear entre o N foliar e os valores SPAD foi observado CARVALHO et al. (2003) trabalhando com a cultura do feijão submetida a diferentes doses de N. ARGENTA et al. (2001) trabalhando com a cultura do milho constataram que, no estágio de seis a sete folhas, não houve relação entre as duas variáveis. Entretanto, nos estádios de 10 a 11 folhas e de espigamento verificaram que o teor de N na folha aumentou linearmente à medida que a leitura com clorofilômetro era maior. Por outro lado, MURDOCK et al. (1997) indicam que o relacionamento linear entre os valores SPAD e o N nas plantas de trigo se restringe a uma determinada faixa, além da qual os valores SPAD tendem a estabilizar com o aumento do N nas plantas. Esse comportamento deve-se ao consumo de luxo do nutriente pelas plantas.

Relação entre N foliar e valores SPAD no experimento em vasos

O coeficiente de correlação entre os valores de N nas plantas aos 18 DAE e os valores SPAD obtidos aos 23 DAE foi de 0,44, não significativo pelo teste t a 1% de probabilidade. O coeficiente de correlação entre os valores de N foliar aos 44 DAE e os valores SPAD obtidos aos 41 DAE foi de 0,9583, significativo pelo teste t a 1% de probabilidade. Não se verificou correlação significativa entre os valores SPAD aos 23 DAE e o N foliar aos 18 DAE, embora a regressão utilizando o modelo linear simples para as duas variáveis dependentes com as doses de N tenham sido significativa. Os coeficientes de determinação nos dois casos não foram elevados, o que indica que nessas épocas as plantas ainda não haviam respondido totalmente às doses de N aplicadas. Por outro lado, a correlação entre o N foliar aos 44 DAE e os valores SPAD aos 41 foi alta. Esse fato, aliado aos resultados do ajuste da regressão dos modelos lineares simples dessas variáveis com as doses de N indica a associação das duas variáveis nessa época com o N disponível. Sendo assim,

nessa época as duas variáveis mostraram-se adequadas para identificação da disponibilidade de N para as plantas.

O modelo linear ajustado entre os valores SPAD obtidos aos 41 DAE e os valores de N foliar aos 44 DAE nas plantas cultivadas em vasos é apresentado na Figura 15. Os resíduos do modelo ajustado são apresentados na Figura 16. O modelo apresentou erro absoluto médio de 4,11%. Da mesma forma que no experimento no campo, a relação entre os valores SPAD e o N foliar apresentaram relação linear.




Figura 15. Modelo linear ajustado entre os valores de N foliar aos 44 DAE e os valores SPAD aos 41 DAE em trigo, cultivar BRS 207, sob cinco doses de nitrogênio (0, 30, 60, 90 e 120 kg N.ha⁻¹).

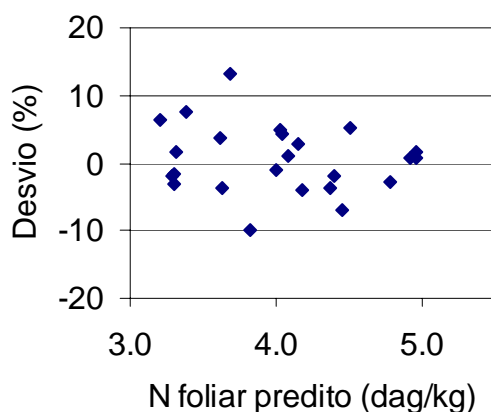


Figura 16. Resíduos do ajuste do modelo linear entre os valores de N foliar aos 44 DAE e os valores SPAD aos 41 DAE em trigo, cultivar BRS 207, sob cinco níveis de nitrogênio (0, 30, 60, 90 e 120 kg N.ha⁻¹).

4.2. Avaliação da classificação utilizando imagens, valores SPAD e teor de nitrogênio foliar

Classificadores com valores SPAD no experimento de campo

Os resultados dos classificadores desenvolvidos com valores SPAD e avaliados utilizando-se validação cruzada são apresentados na Tabela 23.

TABELA 23. Exatidão global e coeficiente kappa dos classificadores desenvolvidos com os valores SPAD coletados em três épocas após a adubação nitrogenada em cobertura na cultura do trigo no experimento de campo

Dias após a adubação	Exatidão global	Coeficiente kappa
8	0,38	0,07
14	0,74	0,61* a
20	0,80	0,70* a

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

O coeficiente kappa do classificador desenvolvido com os valores SPAD coletados aos 8 DAA 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. Com oito dias após a adubação, o teor de clorofila das folhas das plantas de trigo ainda não havia sido influenciado pelas doses de N aplicadas ou o medidor de clorofila não foi capaz de detectar as diferenças. Por outro lado, tanto aos 14 como aos 20 DAA a classificação foi 61 e 70% melhor que uma classificação ao acaso, respectivamente. Entretanto, apesar de MURDOCK et al. (1997) afirmarem que são necessárias três semanas para a resposta ao N aplicado para utilização do medidor de clorofila SPAD 502 em trigo, os classificadores desenvolvidos aos 14 e 20 DAA não foram estatisticamente diferentes.

As matrizes de contingência, elaboradas utilizando-se a técnica de validação cruzada deixando uma amostra de fora (VC) para os classificadores desenvolvidos com valores SPAD coletados aos 8, 14 e 20 DAA no campo, são apresentados nas Tabelas 24, 25 e 26, respectivamente. A exatidão do produtor é a proporção de

amostras de cada classe corretamente classificadas em relação ao número de amostras daquela classe submetidas à classificação.

TABELA 24. Matriz de contingência, elaborada com validação cruzada, do classificador desenvolvido com valores SPAD coletados aos 8 DAA no experimento de campo

Dose N (kg.ha ⁻¹)	Dados de referência		
	0	30	60
0	8	5	3
30	7	5	8
60	0	5	4
Total	15	15	15
Exatidão do produtor	0,53	0,33	0,27

TABELA 25. Matriz de contingência, elaborada com validação cruzada, do classificador desenvolvido com valores SPAD coletados aos 14 DAA no experimento de campo

Dose N (kg.ha ⁻¹)	Dados de referência		
	0	30	60
0	11	1	0
30	2	6	3
60	0	3	9
Total	13	10	12
Exatidão do produtor	0,85	0,60	0,75

TABELA 26. Matriz de contingência, elaborada com validação cruzada, do classificador desenvolvido com valores SPAD coletados aos 20 DAA no experimento de campo

Dose N (kg.ha ⁻¹)	Dados de referência		
	0	30	60
0	13	0	0
30	2	12	4
60	0	3	11
Total	15	15	15
Exatidão do produtor	0,87	0,80	0,73

Na época 8 DAA, conforme indicado pelo valor do coeficiente kappa (Tabela 23), a classificação não foi satisfatória, uma vez que a maior exatidão do produtor observada foi na classe 0 kg N.ha⁻¹, de apenas 53%. Nas demais classes, os erros

foram superiores aos acertos. A menor exatidão do produtor foi verificada na classe 30 kg N.ha⁻¹. A classe que apresentou as maiores exatidões, tanto do produtor como do usuário foi a classe 0 kg N.ha⁻¹, o que indica a maior eficiência do medidor de clorofila SPAD para identificar a deficiência de N do que a suficiência. Verifica-se ainda que embora os coeficientes kappa das classificações aos 14 e aos 20 DAA não tenham diferido estatisticamente, a classificação com o medidor de clorofila aos 20 DAA é mais confiável, concordando com MURDOCK et al. (1997). Aos 14 DAA, na classe 30 kg N.ha⁻¹, 40% das amostras foram classificadas incorretamente, enquanto que aos 20 DAA na mesma classe o erro de omissão foi de apenas 20%.

Classificadores com valores SPAD no experimento em vasos

A exatidão global e o coeficiente kappa dos classificadores desenvolvidos com os valores SPAD coletados aos 15, 23, 27, 34 e 41 DAE e avaliados utilizando-se a técnica de validação cruzada são apresentados na Tabela 27.

TABELA 27. Exatidão global e coeficiente kappa dos classificadores desenvolvidos com os valores coletados aos 15, 23, 27, 34 e 41 DAE no experimento em vasos

Dias após a emergência	Exatidão global	Coeficiente kappa	
15	0,24	0,05	
23	0,28	0,10	
27	0,36	0,20*	a
34	0,40	0,25*	a
41	0,40	0,25*	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 ao nível de 5% de probabilidade.

Os coeficientes kappa dos classificadores desenvolvidos com os valores SPAD coletados aos 15 e 23 DAE no experimento em vasos foram estatisticamente iguais a zero. Isso significa que a classificação obtida é igual a uma classificação ao acaso. Os coeficientes kappa dos classificadores com valores SPAD aos 27, 34 e 41 foram estatisticamente melhores que a classificação ao acaso e não houve diferença estatística entre os mesmos.

Embora a adubação nitrogenada tenha sido realizada praticamente na emergência das plantas, mesmo o classificador desenvolvido aos 41 DAE apresentou classificação apenas 25% melhor que uma classificação ao acaso. Essa baixa classificação pode ser decorrente do reduzido número de repetições, o que pode levar a uma estimativa inadequada da média e matrizes de co-variância das classes.

A matriz de contingência do classificador desenvolvido aos 41 DAE é apresentada na Tabela 28.

TABELA 28. Matriz de contingência, elaborada com validação cruzada, do classificador desenvolvido com valores SPAD coletados aos 41 DAE no experimento em vasos

Dose N (kg.ha ⁻¹)	Dados de referência				
	0	30	60	90	120
0	3	1	1	0	0
30	2	0	2	0	0
60	0	3	1	1	0
90	0	1	1	3	2
120	0	0	0	1	3
Total	5	5	5	5	5
Exatidão do produtor	0,60	0	0,20	0,60	0,60

As classes 0, 90 e 120 kg de N.ha⁻¹ apresentaram os melhores resultados em termos de exatidão do produtor, com acerto de 60% das amostras. Entretanto, na classe 30 kg de N.ha⁻¹ todas as amostras foram classificadas incorretamente, sendo que três das cinco amostras foram atribuídas à classe 60 kg de N.ha⁻¹. Por outro lado, duas das cinco amostras da classe 60 kg de N.ha⁻¹ foram atribuídas à classe 30 kg de N.ha⁻¹. Os valores SPAD nessas classes foram semelhantes, o que levou aos erros de classificação (Figura 6).

Esses resultados são semelhantes aos observados por HINZMAN et al. (1986) que avaliaram a reflectância com espectroradiômetro em trigo de inverno sob três doses de N (0, 60 e 120 kg de N.ha⁻¹). Os autores concluíram que embora fosse sempre possível distinguir as parcelas com dose 0 kg de N.ha⁻¹ daquelas com dose 120 kg de N.ha⁻¹ as parcelas com 60 kg de N.ha⁻¹ nem sempre foram distinguíveis.

Classificador com valores de N foliar no experimento de campo

A matriz de contingência do classificador desenvolvido com valores de N das folhas coletadas aos 21 DAA e os valores da exatidão do produtor são apresentados na Tabela 29.

TABELA 29. Matriz de contingência elaborada com validação cruzada e exatidão do produtor para o classificador desenvolvido com valores de N foliar em amostras coletadas aos 21 DAA

Dose N (kg.ha ⁻¹)	Dados de referência		
	0	30	60
0	13	2	0
30	2	8	1
60	0	5	14
Total	15	15	15
Exatidão do produtor	0,87	0,53	0,93

Esse classificador apresentou um coeficiente kappa de 0,67 e exatidão global de 78%. Verifica-se que ao se utilizar os valores de N foliar para classificação, da mesma forma que a utilização dos valores SPAD (desconsiderando-se a época 8 DAA), a classe com pior classificação foi a de 30 kg de N.ha⁻¹. A maior parte das amostras incorretamente classificadas dessa classe foi atribuída à classe 60 kg de N.ha⁻¹. Esse tipo de erro pode levar um sistema de aplicação automática de N a taxa variada a aplicar uma dose mais baixa do que o recomendado. Por outro lado, a maior exatidão do produtor (93%) foi verificada na classe 60 kg de N.ha⁻¹, indicando que o N foliar pode ser mais eficiente que o medidor de clorofila para identificação de plantas adequadamente nutridas por N.

Classificador com valores de N foliar no experimento em vasos

A exatidão global e o coeficiente kappa dos classificadores desenvolvidos com os valores de N nas plantas aos 10 e 18 DAE e com o N nas folhas aos 44 DAE e avaliados utilizando-se a técnica de validação cruzada são apresentados na Tabela 30.

TABELA 30. Exatidão global e coeficiente kappa dos classificadores desenvolvidos com os valores de N nas plantas aos 10 e 18 DAE e com o N nas folhas aos 44 DAE no experimento em vasos

Dias após a emergência	Exatidão global	Coeficiente kappa
10	0,12	-0,10
18	0,17	0,05
44	0,52	0,40*

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

Os classificadores desenvolvidos com os valores do N nas plantas aos 10 e 18 DAE apresentaram coeficiente kappa estatisticamente igual a zero pelo teste Z a 5% de probabilidade. Esperava-se que a classificação aos 18 DAE fosse melhor, uma vez que o teste F da regressão foi significativo, embora com coeficiente da regressão baixo. Nessa época, pouco depois do perfilhamento, as plantas encontram-se pouco desenvolvidas e ainda não atingiram a fase de grande exigência de N. Sendo assim, ainda não é uma época adequada para caracterização do estado nutricional das plantas de trigo e correlação desse com a disponibilidade de nitrogênio. Por outro lado, aos 44 DAE as plantas já se encontravam iniciando o desenvolvimento das espigas, na fase de grande exigência de N, o que reflete na classificação obtida. Nessa época obteve-se um coeficiente kappa de 0,40 e uma exatidão global de 52%. A matriz de erros desse classificador é apresentado na Tabela 31.

TABELA 31. Matriz de contingência, elaborada com validação cruzada, do classificador desenvolvido com valores de N foliar de amostras coletadas aos 44 DAE no experimento em vasos

Dose N (kg.ha ⁻¹)	Dados de referência				
	0	30	60	90	120
0	4	2	1	0	0
30	1	1	0	0	0
60	0	2	3	1	0
90	0	0	1	1	1
120	0	0	0	3	4
Total	5	5	5	5	5
Exatidão do produtor	0,80	0,20	0,60	0,20	0,80

As classes que apresentaram as menores exatidões do produtor foram as doses 30 e 90 kg de N.ha⁻¹, com apenas uma das cinco amostras classificadas corretamente. As amostras da classe 30 foram classificadas incorretamente como pertencentes às classes 0 e 60 kg de N.ha⁻¹. Por sua vez, na classe 90 o principal erro foi atribuir as amostras à classe 120 kg de N.ha⁻¹. Verifica-se que os valores de N nessa época foram eficientes tanto para identificar a deficiência como a suficiência de N, pois as classes com maiores acertos foram 0 e 120 kg de N.ha⁻¹. Entretanto, acredita-se que o resultado da classificação poderia ter sido melhor se houvessem mais amostras disponíveis, pois mesmo utilizando-se a validação cruzada deixando apenas uma amostra de fora, o número de cinco repetições pode não ter sido suficiente para se obter uma estimativa confiável das médias e matrizes de covariância das classes.

Correlação entre índices espectrais no experimento de campo

As características de reflectância foram extraídas a partir das imagens índice, sendo considerada a medida de reflectância a média dos valores dos pixels em cada imagem índice. As matrizes de correlação entre as médias dos valores dos pixels nas imagens índice aos 8, 14 e 20 DAA são apresentados nas Tabelas 32, 33 e 34, respectivamente.

TABELA 32. Matriz de correlação entre a média dos valores dos pixels nas imagens índice aos 8 DAA

	Evd	VdVm	Vdn	Vmn	NDVI	GNDVI	VmIV	VdIV
VdVm	0,86**							
Vdn	1,00**	0,86**						
Vmn	-0,84**	-0,98**	-0,84**					
NDVI	0,83**	0,95**	0,83**	-0,98**				
GNDVI	0,73**	0,89**	0,73**	-0,91**	0,97**			
VmIV	-0,82**	-0,93**	-0,82**	0,97**	-1,00**	-0,96**		
VdIV	-0,73**	-0,88**	-0,73**	0,91**	-0,98**	-0,99**	0,97**	
IVVd	0,89**	0,94**	0,89**	-0,94**	0,98**	0,96**	-0,97**	-0,96**

** correlação significativa ao nível de 1% de probabilidade

Evd: índice do excesso de verde; VdVm: razão verde-vermelho; Vdn: verde normalizado; Vmn: vermelho normalizado; NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; VmIV: razão vermelho - infravermelho; VdIV: razão verde - infravermelho; e IVVd: índice do excesso de infravermelho e verde.

TABELA 33. Matriz de correlação entre a média dos valores dos pixels nas imagens índice aos 14 DAA

	Evd	VdVm	Vdn	Vmn	NDVI	GNDVI	VmIV	VdIV
VdVm	0,40**							
Vdn	1,00**	0,40**						
Vmn	-0,13	-0,95**	-0,13					
NDVI	0,03	0,88**	0,03	-0,97**				
GNDVI	-0,21	0,74**	-0,21	-0,88**	0,95**			
VmIV	-0,05	-0,88**	-0,05	0,97**	-1,00**	-0,94**		
VdIV	0,20	-0,75**	0,20	0,89**	-0,97**	-1,00**	0,96**	
IVVd	0,21	0,91**	0,21	-0,93**	0,96**	0,91**	-0,95**	-0,91**

** correlação significativa ao nível de 1% de probabilidade

Evd: índice do excesso de verde; VdVm: razão verde-vermelho; Vdn: verde normalizado; Vmn: vermelho normalizado; NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; VmIV: razão vermelho - infravermelho; VdIV: razão verde - infravermelho; e IVVd: índice de excesso de infravermelho e verde.

TABELA 34. Matriz de correlação entre a média dos valores dos pixels nas imagens índice aos 20 DAA

	Evd	VdVm	Vdn	Vmn	NDVI	GNDVI	VmIV	VdIV
VdVm	-0,85**							
Vdn	1,00**	-0,85**						
Vmn	0,84**	-0,97**	0,84**					
NDVI	0,17	0,03	0,17	-0,20				
GNDVI	0,58**	-0,50**	0,58**	0,35**	0,83**			
VmIV	-0,17	-0,04	-0,17	0,21	-1,00**	-0,82**		
VdIV	-0,61**	0,56**	-0,61**	-0,41**	-0,80**	-0,99**	0,79**	
IVVd	0,84**	-0,72**	0,84**	0,61**	0,63**	0,93**	-0,62**	-0,93**

** correlação significativa ao nível de 1% de probabilidade

Evd: índice do excesso de verde; VdVm: razão verde-vermelho; Vdn: verde normalizado; Vmn: vermelho normalizado; NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; VmIV: razão vermelho - infravermelho; VdIV: razão verde - infravermelho; e IVVd: índice de excesso de infravermelho e verde.

Os índices Evd e Vdn apresentaram 100% de correlação nas três épocas estudadas, uma vez que ambos representam uma medida da reflectância na faixa do verde. Na época 8 DAA a correlação entre todos os índices foi significativa. Aos 14 DAA e aos 20 DAA a correlação entre alguns índices não se mostrou significativa, especialmente os índices que exploram a reflectância na faixa do verde e os na faixa do vermelho. Acredita-se que essa alteração no comportamento da correlação entre os índices deveu-se ao desenvolvimento da cultura. Na fase inicial (8 DAA) havia grande influência do solo nas imagens, que apresenta maior reflectância na banda do vermelho. Esse comportamento com relação à reflectância no espectro do vermelho foi observado por ÂNGULO FILHO et al. (2001) trabalhando com a cultura

do feijão. Esses autores observaram, na fase inicial do desenvolvimento da cultura, grande influência da reflectância do solo na faixa equivalente à banda TM3 (vermelho) do satélite Landsat. Com o desenvolvimento da cultura observaram decréscimo gradual até a floração e enchimento de grãos. A partir daí, devido à senescência da cultura e aumento da exposição do solo, verificou-se um aumento da reflectância nessa banda. Esses autores verificaram ainda que na banda TM4 (infravermelho próximo) a reflectância aumentou com o aumento da fitomassa, e que até os 30 dias de desenvolvimento foi muito influenciada pelo solo exposto. Com relação ao índice NDVI, ÂNGULO FILHO et al. (2001) verificaram que os valores do NDVI estão mais relacionados com a reflectância na banda TM4 que na banda TM3. EPIPHANIO e FORMAGGIO (1991) destacam que a diferença na reflectância nessas bandas faz com que o aumento da razão Infravermelho próximo / vermelho seja potencializado, realçando a vegetação.

Esse comportamento pode ser verificado nos valores médios dos índices VdVm, NDVI e VmIV para as três épocas estudadas (Figura 17).

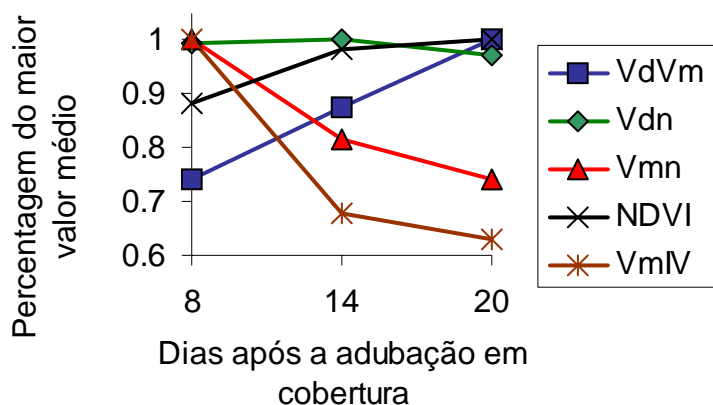


Figura 17. Percentagem dos valores máximos dos índices razão verde-vermelho (VdVm); verde normalizado (Vdn); vermelho normalizado(Vmn), índice de vegetação da diferença normalizado (NDVI) e razão vermelho-infravermelho (VmIV) para as épocas 8, 14 e 20 DAA.

Verificou-se a tendência de aumento nos valores dos índices relacionados ao verde e/ou com os valores de verde no numerador, devido ao desenvolvimento da cultura e cobertura do solo. Pelo mesmo motivo, os índices relacionados ao vermelho apresentaram redução nos valores. Isto pode ser verificado na razão entre vermelho e infravermelho próximo. O vermelho nas imagens foi reduzido devido à cobertura do solo e absorção pela clorofila, enquanto o infravermelho próximo

aumentou devido à maior presença de folhas que refletem esse comprimento de onda e cobertura do solo que o absorve. Isso levou ao decréscimo dos valores dos índices relacionados ao vermelho com o desenvolvimento da cultura.

Correlação entre índices espectrais no experimento em vasos

As matrizes de correlação entre as médias dos valores dos pixels nas imagens índice e média dos valores dos pixels representando folhas no experimento com vasos são apresentadas nas Tabelas 35 e 36, respectivamente.

TABELA 35. Matriz de correlação entre a média dos valores dos pixels nas imagens índice no experimento em vasos

	Evd	VdVm	Vdn	Vmn	NDVI	GNDVI	VmIV	VdIV
VdVm	0,95**							
Vdn	1,00**	0,95**						
Vmn	-0,81**	-0,92**	-0,81**					
NDVI	0,39	0,51**	0,39	-0,73**				
GNDVI	-0,06	0,06	-0,06	-0,34	0,88**			
VmIV	-0,42	-0,51*	-0,42**	0,71**	-0,99**	-0,87**		
VdIV	0,04	-0,07	0,04	0,33	-0,88**	-1,00**	0,88**	
IVVd	0,44	0,53**	0,45	-0,73**	0,99**	0,86**	-0,99**	-0,87**

** correlação significativa ao nível de 1% de probabilidade

Evd: índice do excesso de verde; VdVm: razão verde-vermelho; Vdn: verde normalizado; Vmn: vermelho normalizado; NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; VmIV: razão vermelho - infravermelho; VdIV: razão verde - infravermelho; e IVVd: índice do excesso de infravermelho e verde.

TABELA 36. Matriz de correlação entre a média dos valores dos pixels representando folhas nas imagens índice no experimento em vasos

	Evd	VdVm	Vdn	Vmn	NDVI	GNDVI	VmIV	VdIV
VdVm	0,96**							
Vdn	1,00**	0,96**						
Vmn	-0,86**	-0,96**	-0,86**					
NDVI	-0,62**	-0,44	-0,62**	0,22				
GNDVI	-0,91**	-0,82**	-0,91**	0,66**	0,88**			
VmIV	0,62**	0,45	0,62**	-0,23	-1,00**	-0,88**		
VdIV	0,91**	0,82**	0,91**	-0,67**	-0,87**	-1,00**	0,88**	
IVVd	-0,41	-0,26	-0,41	0,06	0,95**	0,74**	-0,95**	-0,74**

** correlação significativa ao nível de 1% de probabilidade

Evd: índice do excesso de verde; VdVm: razão verde-vermelho; Vdn: verde normalizado; Vmn: vermelho normalizado; NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; VmIV: razão vermelho - infravermelho; VdIV: razão verde - infravermelho; e IVVd: índice do excesso de infravermelho e verde.

O comportamento da correlação entre os índices foi semelhante ao observado no experimento de campo. Os índices Evd e Vdn apresentaram correlação de 100% nos dois casos, a reflectância da imagem e reflectância das folhas. Ao se retirar os pixels relativos ao solo das imagens houve a tendência geral de aumento da correlação entre os índices, especialmente nos que utilizam as bandas do verde. O caso mais extremo ocorreu com o índice GNDVI, que quando se utilizou a média dos pixels de toda a imagem não apresentou correlação significativa com nenhum índice criado com as bandas do visível. Porém, ao se utilizar apenas os pixels de folhas a correlação foi significativa com todos os índices, tanto com os que utilizam as bandas do visível como os que utilizam o infravermelho próximo.

Os índices em que a média dos valores dos pixels das folhas foi maior que a média dos pixels na imagem são apresentados na Figura 18 e os índices que apresentaram comportamento inverso são apresentados na Figura 19.

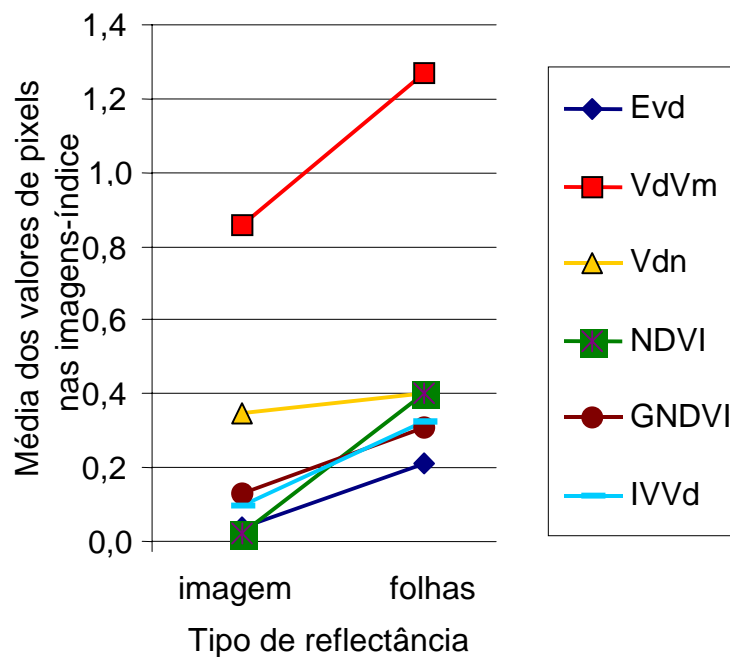


Figura 18. Índices espectrais em que a média dos valores dos pixels na imagem foi inferior à média dos valores dos pixels de folhas no experimento em vasos (Evd: índice do excesso de verde; VdVm: razão verde-vermelho; Vdn: verde normalizado; NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; e IVVd: índice do excesso de infravermelho e verde).

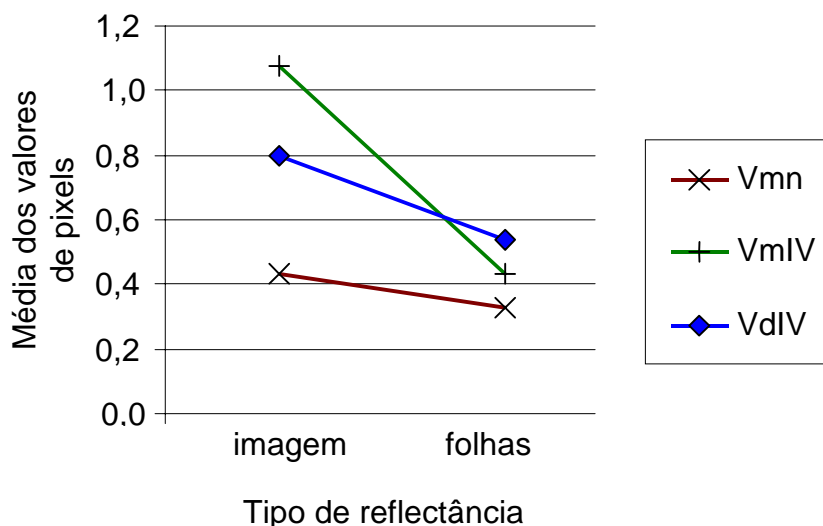


Figura 19. Índices espectrais em que a média dos valores dos pixels na imagem foi superior à média dos valores dos pixels de folhas no experimento em vasos (Vmn: vermelho normalizado; VmIV: razão vermelho - infravermelho; e VdIV: razão verde - infravermelho)

Verificou-se que, de modo geral, a média dos índices que utilizam a banda do verde tendeu a aumentar e a dos índices que utilizam a banda do vermelho a diminuir com a retirada dos pixels de solo. A média do verde normalizado foi a menos afetada pela retirada dos pixels de solo. A média da razão vermelho infravermelho próximo foi bastante reduzida pois a maior parte do vermelho nas imagens estava presente nos pixels de solo e o infravermelho nas folhas. Ao se retirar os pixels de solo, o vermelho foi reduzido e o infravermelho próximo aumentado, proporcionando a grande alteração nos valores desse índice.

Classificadores com características de reflectância no experimento de campo

Foram desenvolvidos classificadores utilizando-se as 511 combinações da média dos pixels nas imagens índice. Uma vez que de cada parcela foram obtidas 3 imagens, um total de 135 vetores de características foram utilizados para elaboração e avaliação dos classificadores por meio da técnica de validação cruzada deixando uma amostra de fora. Na época 14 DAA foram utilizados 133 vetores, uma vez que duas imagens foram descartadas devido a problemas na aquisição. Para cada classificador elaborou-se a matriz de contingência e calculou-se a exatidão global e o coeficiente kappa. Para cada época considerou-se o melhor classificador aquele

com o maior valor do coeficiente kappa. Os melhores classificadores para cada época são apresentados na Tabela 37. Todos os coeficientes kappa foram estatisticamente diferentes de zero pelo teste Z a 5% de probabilidade.

TABELA 37. Melhores classificadores utilizando a média dos valores dos pixels nas imagens índice selecionados pelo coeficiente kappa em cada época

Época	Combinação de índices	Exatidão global	Coeficiente kappa	
8 DAA	GNDVI; IVVd	0,52	0,28*	a
8 DAA	VdVm; NDVI; GNDVI; VmIV	0,52	0,28*	a
14 DAA	Evd; Vdn; VmIV	0,77	0,66*	b
20 DAA	Evd; VdVm; Vmn; GNDVI; VdIV; IVVd	0,80	0,70*	b
20 DAA	VdVm; Vdn; ; Vmn; GNDVI; VdIV; IVVd	0,80	0,70*	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.

GNDVI: índice de vegetação da diferença de verde normalizado; IVVd: índice do excesso de infravermelho e verde; VdVm: razão verde-vermelho; NDVI: índice de vegetação da diferença normalizado; VmIV: razão vermelho - infravermelho; Evd: índice do excesso de verde; Vdn: verde normalizado; Vmn: vermelho normalizado; VdIV: razão verde - infravermelho;

Verifica-se que de forma semelhante ao verificado com os classificadores desenvolvidos com os valores SPAD, os coeficientes kappa dos classificadores desenvolvidos com os dados coletados em estádios mais avançados foi maior. Embora os coeficientes kappa dos melhores classificadores na época 14 e 20 tenham diferido do coeficiente kappa obtido aos 8 DAA, com a utilização da reflectância extraída das imagens índice, todos os coeficientes kappa diferiram estatisticamente de zero, o que não ocorreu com os valores SPAD. O medidor de clorofila utiliza apenas o vermelho e o infravermelho próximo para avaliar o conteúdo de clorofila nas folhas. Entretanto, em todas as combinações selecionadas com os dados das imagens a banda verde estava presente, indicando sua importância para classificação. Acredita-se que esse pode ter sido um diferencial que proporcionou melhores resultados ao classificador utilizando os dados das imagens.

Aos 14 DAA, o melhor classificador combinou os índices Evd e Vdn, mostrando que embora altamente correlacionados, o efeito conjunto dos índices é importante para a classificação. Além disso, combinou o índice VmIV, evidenciando o efeito do N sobre a biomassa, relacionada ao infravermelho próximo.

Aos 20 DAA, os dois classificadores selecionados podem ser considerados praticamente iguais, uma vez que a média dos valores dos pixels nas imagens

índices obtidas com Evd e Vdn apresentaram correlação 1,0. Além disso, dos seis índices combinados cinco utilizam a banda verde, devido à correlação das doses de N com a clorofila e, conseqüentemente, com a tonalidade de verde das plantas.

O resumo da análise de variância para as médias dos valores dos pixels nas imagens índice no experimento de campo para as épocas 8, 14 e 20 DAA é apresentado na Tabela 38.

TABELA 38. Resumo da análise de variância para as médias dos valores dos pixels nas imagens índice no experimento de campo para as épocas 8, 14 e 20 DAA

Índice	8 DAA		14 DAA		20 DAA	
	F	Pr > F	F	Pr > F	F	Pr > F
Evd	3,80	0,0250	49,92	<0,0001	5,26	0,0063
VdVm	1,32	0,2698	3,82	0,0243	3,16	0,0456
Vdn	3,80	0,0249	49,93	<0,0001	5,26	0,0064
Vmn	0,46	0,6329	17,24	<0,0001	9,27	0,0002
NDVI	0,25	0,7821	24,80	<0,0001	45,49	<0,0001
GNDVI	0,67	0,5128	48,34	<0,0001	18,50	<0,0001
VmIV	0,24	0,7850	23,39	<0,0001	42,63	<0,0001
VdIV	0,85	0,4276	47,27	<0,0001	12,90	<0,0001
IVVd	0,42	0,6561	10,80	<0,0001	2,56	0,0811

Evd: índice do excesso de verde; VdVm: razão verde-vermelho; Vdn: verde normalizado; Vmn: vermelho normalizado; NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; VmIV: razão vermelho - infravermelho; VdIV: razão verde - infravermelho; e IVVd: índice do excesso de infravermelho e verde.

Verifica-se que aos 8 DAA nenhum índice apresentou média com diferença significativa pelo teste F ao nível de 1 % de probabilidade. Aos 14 e aos 20 DAA, entretanto, praticamente todos os índices apresentaram diferença significativa, o que pode explicar a maior eficiência dos classificadores nessas épocas.

As matrizes de contingência e as exatidões do usuário dos melhores classificadores com a média dos valores dos pixels aos 14 e 20 DAA são apresentados nas Tabelas 39 e 40, respectivamente. Os dois classificadores selecionados aos 20 DAA apresentaram matrizes de contingência iguais.

TABELA 39. Matriz de contingência, elaborada com validação cruzada, do melhor classificador desenvolvido com a média dos valores dos pixels das imagens índice, aos 14 DAA

Dose N (kg.ha ⁻¹)	Dados de referência		
	0	30	60
0	37	3	0
30	8	30	7
60	0	12	36
Total	45	45	43
Exatidão do produtor	0,82	0,67	0,84

TABELA 40. Matriz de contingência, elaborada com validação cruzada, dos melhores classificadores desenvolvidos com a média dos valores dos pixels das imagens índice, aos 20 DAA

Dose N (kg.ha ⁻¹)	Dados de referência		
	0	30	60
0	39	4	1
30	6	33	8
60	0	8	36
Total	45	45	45
Exatidão do produtor	0,87	0,73	0,80

Acredita-se que aos 14 DAA a cultura ainda não havia respondido totalmente ao N aplicado, o que pode ter contribuído para o menor acerto nessa época. Embora o acerto na classe 60 kg N.ha⁻¹ tenha sido menor aos 20 DAA, o acerto nas classes 0 e 30 kg de N.ha⁻¹ foi o que garantiu um melhor coeficiente kappa aos 20 DAA.

Classificadores com características de reflectância no experimento em vasos

Foram analisados os resultados dos classificadores resultantes da combinação de até no máximo três índices. Foram testadas 129 combinações, sendo nove com os índices isoladamente, 36 com os índices combinados dois a dois e 84 combinações com os índices três a três. Utilizou-se a técnica de validação cruzada deixando uma amostra de fora para avaliação dos classificadores. Foram desenvolvidos classificadores com a média dos pixels na imagem e a média dos pixels representando as folhas do trigo. Os melhores classificadores são apresentados na Tabela 41.

TABELA 41. Melhores classificadores utilizando a média dos valores dos pixels nas imagens índice e média dos valores dos pixels representando folhas, selecionados pelo coeficiente kappa, no experimento em vasos

Tipo de classificador	Combinação de índices utilizada no classificador	Exatidão global	Coeficiente kappa
Média dos pixels na imagem	Evd; VmIV	0,60	0,50*
	Vdn; VmIV	0,60	0,50*
Média dos pixels de folhas	GNDVI	0,60	0,50*
	VdIV	0,60	0,50*

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

Evd: índice do excesso de verde; VmIV: razão vermelho - infravermelho; Vdn: verde normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; e VdIV: razão verde – infravermelho.

Os quatro classificadores selecionados apresentaram o mesmo coeficiente kappa e exatidão global. Quando se utilizou a média dos valores dos pixels de folhas, os melhores resultados foram obtidos por classificadores univariados. Por outro lado quando se utilizou a média dos pixels na imagem, os melhores classificadores utilizaram a combinação de dois índices. Verifica-se que nos dois casos os índices combinados um estava relacionado ao verde (Evd e Vdn) e outro relacionado ao vermelho (VmIV). Os índices Evd e Vdn refletem a mesma informação relativa às folhas, como pode ser verificado pela correlação entre eles (Tabela 36), O outro índice carrega informação acerca do solo, que apresenta alta reflectância no vermelho. As plantas nas doses mais elevadas desenvolvem-se mais e cobrem mais o solo, assim como maior absorção do vermelho pela clorofila, de modo que com o aumento da dose de N a média dos valores de pixel na imagem obtida com esse índice tende a diminuir.

Na Tabela 42 é apresentado o resumo dos resultados da análise de variância da média dos valores dos pixels das imagens índice para as cinco doses de N.

TABELA 42. Resumo da análise de variância da média dos valores dos pixels das imagens índice para as cinco doses de N no experimento em vasos

Índice	F	Pr > F
Evd	2,80	0,0538
VdVm	1,20	0,3396
Vdn	2,80	0,0539
Vmn	0,58	0,6819
NDVI	3,41	0,0279
GNDVI	8,99	0,0003
VmIV	3,29	0,0318
VdIV	7,75	0,0006
IVVd	2,91	0,0476

Evd: índice do excesso de verde; VdVm: razão verde-vermelho; Vdn: verde normalizado; Vmn: vermelho normalizado; NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; VmIV: razão vermelho - infravermelho; VdIV: razão verde - infravermelho; e IVVd: índice do excesso de infravermelho e verde.

Verifica-se que apenas para os índices NDVI, GNDVI, VdIV e IVVd o teste F foi significativo a 5% de probabilidade. Entretanto, os índices que proporcionaram a melhor combinação foram o Evd ou Vdn associado ao VdIV apesar de individualmente não ter sido significativo. Isso demonstra a importância do efeito conjunto das características para classificação.

Os resultados obtidos ao se eliminar os pixels de solo e cálculo da média apenas dos pixels representando folhas em cada imagem são apresentados na Tabela 43.

TABELA 43. Resumo da análise de variância da média dos valores dos pixels representando folhas nas imagens índice para as cinco doses de N no experimento em vasos

Índice	F	Pr > F
Evd	19,04	<0,0001
VdVm	9,22	0,0002
Vdn	19,06	<0,0001
Vmn	4,25	0,0119
NDVI	4,50	0,0093
GNDVI	14,92	<0,0001
VmIV	4,51	0,0092
VdIV	14,15	<0,0001
IVVd	2,04	0,1277

Evd: índice do excesso de verde; VdVm: razão verde-vermelho; Vdn: verde normalizado; Vmn: vermelho normalizado; NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença de verde normalizado; VmIV: razão vermelho - infravermelho; VdIV: razão verde - infravermelho; e IVVd: índice do excesso de infravermelho e verde.

Nesse caso, com exceção do IVVd, o teste F foi significativo a 5% para todas as médias, indicando a influência das doses de N sobre a reflectância das folhas das plantas. Verifica-se que os índices que proporcionaram a melhor classificação (GNDVI e VdIV) não foram aqueles que proporcionaram maior F. Embora o teste F não significativo indique que a variável não será útil para classificação, o teste F significativo indica que pelo menos um contraste entre médias é significativo. Entretanto pode ocorrer que as demais classes não sejam adequadamente separadas por essa variável. Isso concorda com as afirmações de (KHATTREE e NAIK, 2000) e o raciocínio é válido também para a MANOVA e o teste T^2 de Hotelling, o equivalente multivariado ao teste F.

As matrizes de contingência e as exatidões do produtor dos melhores classificadores desenvolvidos com a média dos pixels nas imagens índice e a média dos valores dos pixels representando folhas são apresentados nas Tabelas 44 e 45, respectivamente. Tanto no caso da média das imagens como na média dos pixels de folhas os dois classificadores selecionados apresentaram matrizes de contingência iguais.

TABELA 44. Matriz de contigência e exatidões do produtor do classificador desenvolvido com a média dos pixels nas imagens obtidas a partir do processamento com os índices Evd e VmIV para o experimento em vasos

Dose N (kg.ha ⁻¹)	Dados de referência				
	0	30	60	90	120
0	3	2	1	0	0
30	2	3	1	0	0
60	0	0	3	1	0
90	0	0	0	4	2
120	0	0	0	0	3
Total	5	5	5	5	5
Exatidão do produtor	0,60	0,60	0,60	0,80	0,40

TABELA 45. Matriz de contigência e exatidões do produtor do classificador desenvolvido com a média dos dos pixels representando folhas nas imagens obtidas a partir do processamento com o índice GNDVI para o experimento em vasos

Dose N (kg.ha ⁻¹)	Dados de referência				
	0	30	60	90	120
0	3	1	0	0	0
30	1	1	1	0	0
60	1	3	3	0	1
90	0	0	1	5	1
120	0	0	0	0	3
Total	5	5	5	5	5
Exatidão do produtor	0,60	0,20	0,60	1,00	0,60

Embora a exatidão e coeficiente kappa dos dois classificadores tenha sido a mesma, a classificação utilizando a média das imagens associando os dois classificadores foi vantajosa. Embora não tenha obtido acerto de 100% em nenhuma classe, a menor exatidão do usuário foi verificada na classe 120 kg de N.ha⁻¹, com 40% de acerto (Tabela 44). Quando se utilizou a média dos pixels representando folhas, na classe 30 kg de N.ha⁻¹ o classificador acertou apenas uma das cinco amostras. O classificador desenvolvido com os valores SPAD coletados aos 41 DAE apresentou comportamento semelhante, quando classificou incorretamente todas as amostras da classe 30 kg de N.ha⁻¹. Acredita-se que a média dos valores de todos os pixels das imagens índice carregou informação acerca do desenvolvimento das

plantas e conseqüente cobertura do solo. Quando se utilizou a média dos pixels representando folhas essa informação foi descartada, restando somente a informação acerca da reflectância das folhas, informação semelhante à obtida pelo medidor de clorofila.

Classificadores com características de textura do dossel no experimento de campo

Os melhores classificadores para cada época são apresentados na Tabela 46. O comportamento foi semelhante ao observado com os classificadores somente com as características de reflectância: os classificadores desenvolvidos com os dados coletados aos 14 e aos 20 DAA propiciaram melhor classificação que aos oito DAA.

TABELA 46. Melhores classificadores utilizando a média dos valores dos pixels nas imagens índice e os momentos do histograma, selecionados pelo valor coeficiente kappa, em cada época

Época	Combinação de índices	Exatidão global	Coeficiente kappa	
8 DAA	Evd; NDVI; GNDVI; IVVd	0,59	0,39*	a
14 DAA	VdVm; Vdn; GNDVI; IVVd	0,79	0,69*	b
20 DAA	Vdn; VdIV	0,81	0,71*	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.

Verifica-se que nesse tipo de classificador o valor da banda verde para classificação ficou também evidenciado. Na época 8 DAA, dos quatro índices utilizados na combinação, três relacionam-se à banda verde e apenas um à banda do vermelho. Aos 14 DAA, apenas no índice VdVm a banda vermelha tem influência importante e aos 20 DAA a banda vermelha não foi utilizada nos dois índices que combinados proporcionaram o melhor resultado.

Esses resultados indicam que ao se utilizar as características de textura a importância da banda vermelha para identificação do estado nutricional das plantas por N diminui. Nos estádios menos avançados, entretanto, onde o teor de clorofila foliar ainda não foi totalmente influenciado pelas doses de N, a informação contida na banda vermelha parece ser importante, mesmo utilizando-se as características de textura. Provavelmente, a primeira resposta ao N das plantas ocorra na forma de um maior desenvolvimento do dossel e conseqüente cobertura do solo, informação que aparentemente está relacionada à banda vermelha. Entretanto, à medida que a

resposta das plantas em termos de clorofila se acentua, a informação de reflectância e textura da banda vermelha parece diminuir em importância em relação à informação da banda verde.

As matrizes de contingência e as exatidões do usuário dos melhores classificadores com a média dos valores dos pixels e características de textura desenvolvidos aos 8, 14 e 20 DAA são apresentados nas Tabelas 47, 48 e 49, respectivamente.

TABELA 47. Matriz de contingência e exatidões do produtor, elaborada com validação cruzada, dos melhores classificadores desenvolvidos com a média dos valores dos pixels e características de textura das imagens índice, aos 8 DAA

Dose N (kg.ha ⁻¹)	Dados de referência		
	0	30	60
0	29	5	12
30	6	23	5
60	10	17	28
Total	45	45	45
Exatidão do produtor	0,64	0,51	0,62

TABELA 48. Matriz de contingência e exatidões do produtor, elaborada com validação cruzada, dos melhores classificadores desenvolvidos com a média dos valores dos pixels e características de textura das imagens índice, aos 14 DAA

Dose N (kg.ha ⁻¹)	Dados de referência		
	0	30	60
0	40	5	0
30	5	33	10
60	0	7	33
Total	45	45	43
Exatidão do produtor	0,89	0,73	0,77

TABELA 49. Matriz de contingência e exatidões do produtor, elaborada com validação cruzada, dos melhores classificadores desenvolvidos com a média dos valores dos pixels e características de textura das imagens índice, aos 20 DAA

Dose N (kg.ha ⁻¹)	Dados de referência		
	0	30	60
0	43	6	1
30	1	31	9
60	1	8	35
Total	45	45	45
Exatidão do produtor	0,97	0,69	0,78

Verifica-se que da mesma forma que com os classificadores desenvolvidos apenas com as características de reflectância, nas três épocas a classe que apresentou menor exatidão do produtor foi a classe de 30 kg de N.ha⁻¹, seguida pela classe 60 kg de N.ha⁻¹. Os classificadores com valores SPAD apresentaram comportamento semelhante, o que reforça a indicação que as características utilizadas são mais eficientes para identificar a deficiência das plantas de trigo por N do que a suficiência.

Avaliação da utilização de características de textura do dossel no experimento de campo

Os resultados da exatidão global e coeficiente kappa para os classificadores elaborados apenas com as características de reflectância e para os classificadores elaborados com as características de reflectância e textura para as épocas 8, 14 e 20 DAA são apresentados nas Tabelas 50, 51 e 52, respectivamente.

TABELA 50. Resultados da exatidão global e coeficiente kappa dos classificadores desenvolvidos para a época 8 DAA com características de reflectância e com características de reflectância e textura do dossel extraídas das imagens índice

Época	Tipo de classificador	Exatidão global	Coeficiente kappa	
8 DAA	reflectância	0,52	0,28*	a
	reflectância e textura	0,59	0,39*	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 ao nível de 5% de probabilidade.

TABELA 51. Resultados da exatidão global e coeficiente kappa dos classificadores desenvolvidos para a época 14 DAA com características de reflectância e com características de reflectância e textura do dossel extraídas das imagens índice

Época	Tipo de classificador	Exatidão global	Coeficiente kappa	
14 DAA	reflectância	0,77	0,66*	a
	reflectância e textura	0,80	0,70*	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 ao nível de 5% de probabilidade.

TABELA 52. Resultados da exatidão global e coeficiente kappa dos classificadores desenvolvidos para a época 20 DAA com características de reflectância e com características de reflectância e textura do dossel extraídas das imagens índice

Época	Tipo de classificador	Exatidão global	Coeficiente kappa	
20 DAA	reflectância	0,8	0,70*	a
	reflectância e textura	0,81	0,71*	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 ao nível de 5% de probabilidade.

Os coeficientes kappa obtidos com os classificadores elaborados apenas com as características de reflectância e com os classificadores elaborados com as características de reflectância e textura para as épocas 8, 14 e 20 DAA são apresentados na Figura 20.




Figura 20. Coeficientes kappa dos melhores classificadores desenvolvidos com as características de reflectância e reflectância e textura para as épocas 8, 14 e 20 DAA.

Não houve diferença significativa a 5% de probabilidade entre os coeficientes kappa obtidos aos 8, 14 e 20 DAA para os classificadores desenvolvidos com reflectância e os desenvolvidos com reflectância e textura. Aos 8 DAA ao se utilizar os valores SPAD para classificação obteve-se exatidão foi 38% e coeficiente kappa de 0,07, estatisticamente igual a uma classificação ao acaso.

Nesse trabalho não foi possível identificar o efeito de dois fatores distintos: o estágio de desenvolvimento da cultura e o número de dias após a adubação nitrogenada. O mais provável é que haja uma interação entre os dois fatores influenciando a identificação do estado nutricional. Se o N for aplicado na cultura em um estágio inicial, logo após a emergência por exemplo, acredita-se que o número de dias após a adubação, necessários para a identificação, será maior do que quando a adubação for realizada em um estágio mais avançado.

A utilização de características de textura não promoveu ganhos em termos de classificação. Acredita-se que a informação sobre a textura do dossel possa ser útil para classificação, especialmente nos estádios menos avançados, entretanto o fator mais importante para a identificação do estado nutricional por N foi a reflectância do dossel.

Comparação entre classificadores SPAD, N foliar e imagens no experimento de campo

Os resultados da exatidão global e coeficiente kappa para as épocas 8, 14 e 20 DAA são apresentados nas Tabelas 53, 54 e 55, respectivamente. Os coeficientes kappa para as épocas e tipo de classificador são ilustrados na Figura 21. Embora as amostras para análise de N foliar tenham sido coletadas aos 21 DAA, o coeficiente kappa do classificador desenvolvido com os resultados foi comparado ao classificador com características das imagens e SPAD coletados aos 20 DAA.

TABELA 53. Resultados da exatidão global e coeficiente kappa dos classificadores desenvolvidos para a época 8 DAA com características de reflectância extraídas da imagem e SPAD

Época	Tipo de classificador	Exatidão global	Coeficiente kappa	
8 DAA	imagem reflectância e textura	0,59	0,39*	a
	imagem reflectância	0,52	0,28*	a
	SPAD	0,38	0,07	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 ao nível de 5% de probabilidade.

TABELA 54. Resultados da exatidão global e coeficiente kappa dos classificadores desenvolvidos para a época 14 DAA com características de reflectância extraídas da imagem e SPAD

Época	Tipo de classificador	Exatidão global	Coeficiente kappa	
14 DAA	imagem reflectância e textura	0,80	0,70*	a
	imagem reflectância	0,77	0,66*	a
	SPAD	0,74	0,61*	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 ao nível de 5% de probabilidade.

TABELA 55. Resultados da exatidão global e coeficiente kappa dos classificadores desenvolvidos com características de reflectância extraídas da imagem e SPAD para a época 14 DAA e do classificador desenvolvido aos 21 DAA com resultados da análise foliar

Época	Tipo de classificador	Exatidão global	Coeficiente kappa	
20 DAA	imagem reflectância e textura	0,81	0,71*	a
	imagem reflectância	0,80	0,70*	a
	SPAD	0,80	0,70*	a
21 DAA	N foliar	0,78	0,67*	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 ao nível de 5% de probabilidade.




Figura 21. Coeficientes kappa dos classificadores desenvolvidos com valores SPAD, características de reflectância e características de reflectância e textura extraídas das imagens aos 8, 14 e 20 DAA e classificador desenvolvido com valores de N foliar aos 21 DAA.

Os classificadores desenvolvidos com as características extraídas das imagens, mostraram-se superiores estatisticamente ao classificador desenvolvido com os valores SPAD aos 8 DAA. Aos 14 DAA e aos 20 a diferença entre os coeficientes kappa não foi significativa.

Acredita-se que a maior eficiência dos classificadores com as características extraídas das imagens em relação aos classificadores SPAD aos 8 DAA deve-se ao tipo de informação extraída. O SPAD realiza estimativa pontual da clorofila nas folhas das plantas, ao passo que a informação extraída das imagens integra informação do dossel da cultura. O medidor de clorofila utiliza apenas o vermelho e o infravermelho próximo, ao passo que das imagens foram extraídas também informações acerca do verde e do azul. Além disso, ao se utilizar a média dos valores dos pixels a informação engloba, além da cor das folhas, informação sobre a cobertura do solo e variação de tonalidade de verde. ADAMSEN et al. (1999) também verificaram que as medições do dossel (índices) mostraram-se mais sensíveis à senescência incipiente do que o SPAD que utilizava observações pontuais no topo do dossel.

A presença de solo nas imagens, em maior ou menor grau, afeta a média dos valores dos pixels, assim como a variação de tonalidade de verde entre as diversas

partes das plantas. Sabe-se que o nitrogênio é um nutriente bastante móvel na planta, de forma que em plantas deficientes esse nutriente é mobilizado nas folhas mais velhas e direcionado para as folhas mais novas. Esse é um dos motivos da senescência precoce de folhas em plantas deficientes, o que acarreta nessas plantas um gradiente de tonalidade de verde, com as folhas mais velhas mais amareladas. Essa informação não é avaliada pelo medidor de clorofila, mas está presente nas imagens do dossel. Por outro lado, as informações extraídas das imagens estão sujeitas a diversos tipos de “ruídos” provocados por fatores ambientais, sendo o principal deles a iluminação. Além da iluminação, pode-se citar ainda a presença de plantas daninhas e/ou falhas no plantio que podem prejudicar a classificação com as informações extraídas das imagens.

Comparação entre classificadores SPAD, N foliar e imagens no experimento em vasos

Os resultados da exatidão global e coeficiente kappa para as épocas e tipos de classificadores desenvolvidos a partir dos dados coletados no trigo cultivado em vasos são apresentados na Tabela 56.

TABELA 56. Resultados da exatidão global e coeficiente kappa para as épocas e tipos de classificadores desenvolvidos a partir das imagens, valores SPAD e N foliar no trigo cultivado em vasos

Tipo de classificador	Exatidão global	Coeficiente kappa	
Média dos pixels na imagem aos 43 DAE	0,60	0,50*	a
Média dos pixels de folhas aos 43 DAE	0,60	0,50*	a
N foliar aos 44 DAE	0,52	0,40*	a
SPAD aos 41 DAE	0,40	0,25*	a

* Estatisticamente diferente de zero pelo teste Z ao nível de 5% de probabilidade
Os coeficientes kappa seguidos da mesma letra não diferiram pelo teste Z ao nível de 5% de probabilidade.

Não houve diferença estatística entre os classificadores desenvolvidos, indicando que as técnicas utilizadas para caracterizar o estado nutricional das plantas de trigo, nas condições em que foram cultivadas, são equivalentes. Deve-se ressaltar que essa etapa do trabalho foi realizada com as plantas cultivadas em vasos, com poucas repetições e as imagens obtidas sob iluminação controlada. Mas os resultados estão de acordo com os do experimento realizado no campo. Com as

plantas em estágio mais avançado onde o estado nutricional por N já se manifestou, a utilização de imagens é equivalente ao medidor de clorofila ou análises foliares, técnicas tradicionalmente utilizadas para caracterização do estado nutricional por N.

Avaliação da combinação de características no experimento de campo

O número de índices combinados e sua frequência nos classificadores cujos coeficientes kappa não diferiram do maior valor observado são apresentados na Tabela 57 para a utilização de características de reflectância e na Tabela 58 para a utilização de características de reflectância e textura. Devido ao número de repetições, quando se utilizou características de textura só foi possível testar as combinações de até seis índices.

TABELA 57. Número de índices combinados e sua frequência nos classificadores com a utilização de características de reflectância cujos coeficientes kappa não diferiram do maior valor observado nas 3 épocas de obtenção de imagens

Número de índices combinados	Frequência de ocorrência		
	8 DAA	14 DAA	20 DAA
1	2	0	0
2	20	17	0
3	71	64	6
4	81	115	28
5	63	121	79
6	50	72	77
7	18	35	36
8	2	9	9
9	0	1	1
Total de classificadores	307	434	236

TABELA 58. Número de índices combinados e sua frequência nos classificadores com a utilização de características de reflectância e textura cujos coeficientes kappa não diferiram do maior valor observado nas 3 épocas de obtenção de imagens

Número de índices combinados	Frequência de ocorrência		
	8 DAA	14 DAA	20 DAA
1	2	2	2
2	9	15	11
3	20	30	62
4	35	28	81
5	21	14	52
6	2	2	10
Total de classificadores	89	91	218

Nas três épocas, ao se utilizar somente as características de reflectância, o número de classificadores selecionados foi maior, ou seja, mais classificadores apresentaram coeficientes kappa que não diferiram do maior valor obtido. Isso se deve ao fato de que, embora a diferença entre os coeficientes kappa, utilizando ou não as características de textura não tenha sido significativa, o maior coeficiente kappa obtido foi maior utilizando a textura do dossel.

Utilizando-se somente as características de reflectância, apenas aos 8 DAA classificadores univariados foram incluídos entre os classificadores selecionados. Com as características de textura, aos 14 e aos 20 DAA, dois classificadores com dados extraídos de apenas um índice foram incluídos entre os melhores classificadores. Isso indica que a utilização de características extraídas de mais de um índice é importante, devido ao efeito conjunto das variáveis. Por outro lado, nos casos em que o equipamento não permitir a aquisição de pelo menos três bandas para obtenção de mais de um índice, pode ser vantajoso a utilização de características de textura das imagens do dossel.

De modo geral, os coeficientes kappa dos classificadores selecionados foram maiores com a utilização das características de textura. As Figuras 22, 23 e 24 ilustram a frequência de ocorrência dos coeficientes kappa observados entre os classificadores selecionados aos 8, 14 e 20 DAA, respectivamente.




Figura 22. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 8 DAA utilizando as características de reflectância (a) e as características de reflectância e textura (b).

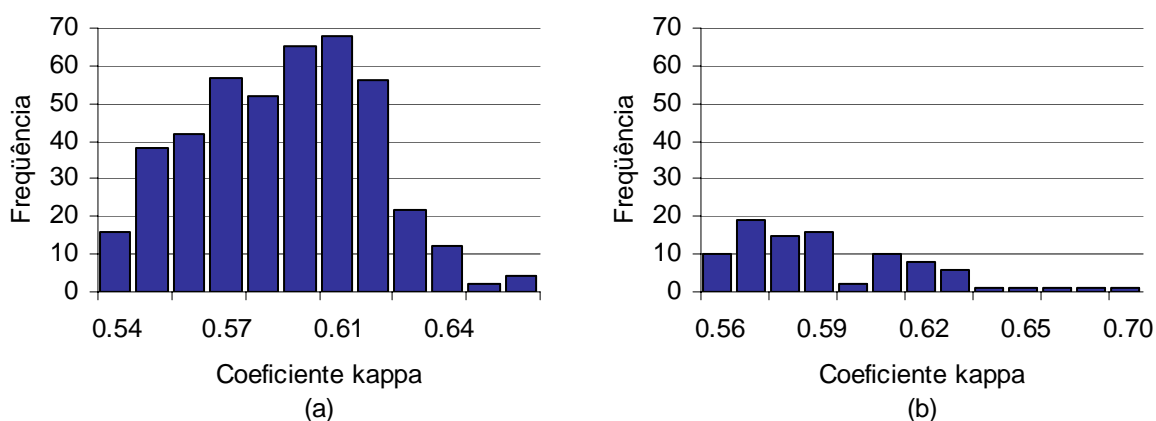


Figura 23. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 14 DAA utilizando as características de reflectância (a) e as características de reflectância e textura (b).




Figura 24. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 20 DAA utilizando as características de reflectância (a) e as características de reflectância e textura (b).

Aos 8 DAA, embora os maiores coeficientes kappa não tenham diferido, com a utilização das características de textura, a faixa dos coeficientes kappa selecionados foi de 0,24 a 0,39, ao passo que utilizando-se somente as características de reflectância o coeficiente kappa dos classificadores selecionados variou de 0,14 a 0,28.

A faixa dos coeficientes kappa dos classificadores selecionados utilizando características de reflectância aos 14 DAA foi de 0,54 a 0,66. Na mesma época ao se utilizar características de reflectância e textura os coeficientes kappa dos classificadores selecionados variaram de 0,56 a 0,70.

Aos 20 DAA, utilizando-se apenas características de reflectância os coeficientes kappa variaram de 0,58 a 0,70 e ao se acrescentar textura os valores variaram de 0,58 a 0,71, resultados praticamente idênticos.

A época 20 DAA mostrou-se mais favorável à classificação. Nessa época a utilização de características de textura não promoveu ganhos em termos de classificação. Por sua vez a época 14 DAA mostrou-se melhor que a época 8 DAA para classificação e em ambas a utilização de características de textura foi importante, especialmente aos 8 DAA. Na época 20 DAA a escolha dos índices a serem combinados para classificação não é muito crítica, pois o número de combinações que produzem classificação satisfatória é grande. Entretanto, nas fases mais jovens a escolha deve ser mais cuidadosa, e a utilização das características de textura pode ser vantajosa.

Avaliação da combinação de características no experimento em vasos

O número de índices combinados e sua frequência nos classificadores cujos coeficientes kappa não diferiram do maior valor observado utilizando a média dos valores dos pixels nas imagens índice e a média dos pixels de folhas nas imagens índice são apresentados na Tabela 59.

TABELA 59. Número de índices combinados e sua frequência nos classificadores com a utilização de características de reflectância cujos coeficientes kappa não diferiram do maior valor observado para os classificadores desenvolvidos com a média dos pixels nas imagens e a média dos pixels representando folhas

Número de índices combinados	Tipo	
	Média dos pixels na imagem	Média dos pixels de folhas
1	1	5
2	21	20
3	32	0
Total de classificadores	54	25

Verificou-se que ao se utilizar a média dos valores dos pixels nas imagens, maior número de classificadores apresentou valor de coeficiente kappa estatisticamente igual ao maior coeficiente kappa obtido. Dos 129 classificadores desenvolvidos com a média das imagens, 53 classificadores não apresentaram coeficiente kappa estatisticamente diferente do maior valor observado, de acordo com os resultados do teste Z a 5%. Por outro lado, ao se utilizar a média dos pixels representando folhas, 25 dos 129 classificadores foram selecionados. A Figura 25 ilustra os coeficientes kappa observados e sua frequência entre os classificadores selecionados ao se utilizar a média dos pixels das imagens ou a média dos pixels representando folhas.

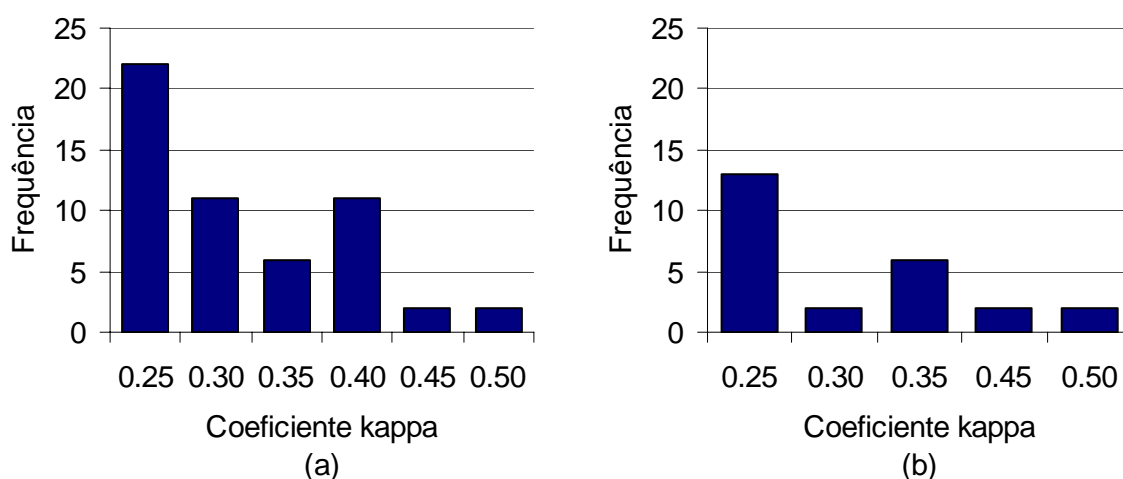


Figura 25. Coeficientes kappa observados e sua frequência entre os classificadores selecionados ao se utilizar a média dos valores dos pixels nas imagens (a) ou a média dos valores dos pixels representando folhas (b) no experimento em vasos.

Acredita-se que a vantagem ao se utilizar a média das imagens deve-se ao fato de que nesses valores é integrada a informação sobre a reflectância das folhas e do solo. Além da tonalidade de verde das folhas, os valores representam a cobertura do solo, ou seja, o desenvolvimento das plantas. Essa informação não é representada na média dos valores dos pixels das folhas.

4.3. Avaliação da resposta da cultura do trigo à adubação nitrogenada em cobertura e parcelamento

Para definição de estratégia para correção da deficiência de N durante o ciclo da cultura do trigo, deve-se identificar a deficiência desse nutriente em tempo hábil para que a adubação possa ser realizada e a deficiência corrigida sem prejuízo à produtividade. Sendo assim, avaliou-se o efeito de diferentes doses de N nas épocas tradicionalmente utilizadas para adubação em cobertura na cultura do trigo. Assumiu-se que a dose correta a ser aplicada em cobertura é de 60 kg de N.ha⁻¹ e que a segunda aplicação de N em cobertura seria realizada para complementar as doses aplicadas na primeira adubação (0,30 e 60 kg de N.ha⁻¹).

A correlação entre as variáveis agrônômicas relacionadas com as doses de N avaliadas são apresentadas na Tabela 60.

TABELA 60. Correlação de Pearson entre as variáveis altura de plantas, produtividade, biomassa seca, massa específica e índice de colheita

	Altura de plantas	Produtividade	Biomassa seca	Massa específica
Produtividade	0,76 **			
Biomassa seca	0,73 **	0,92 **		
Massa específica	- 0, 58 **	-0,71 **	-0,61 **	
Índice de colheita	-0,46 **	-0,57 **	-0,73 **	0,30

** Correlação significativa ao nível de 1% de probabilidade, pelo teste F.

Todos os parâmetros avaliados mostraram-se correlacionados, com exceção do índice de colheita com a massa específica. A correlação positiva entre produtividade e biomassa seca, indica que o maior desenvolvimento vegetativo foi eficiente para aumentar a área foliar e a capacidade fotossintética, o que refletiu em maior produtividade. Verificou-se ainda que a produtividade foi positivamente

correlacionada com altura de plantas, indicando que o aumento na dose de N propiciou aumento na produtividade e na altura das plantas, não se verificando acamamento nas maiores doses de N. Por outro lado, a produtividade foi negativamente correlacionada com a massa específica, indicando que com o aumento da produtividade o desenvolvimento dos grãos foi prejudicado.

Altura de plantas

O resumo da análise de variância para a característica altura de plantas é apresentado na Tabela 61 e as médias dos tratamentos são apresentadas na Tabela 62. A média geral foi 92,1 cm e o coeficiente de variação 2,24.

TABELA 61. Quadro de análise de variância para altura de plantas nos tratamentos

Fator de Variação.	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Tratamento	8	465,85	58,23	13,64	< 0,0001
Resíduo	35	149,39	4,27		
Total	43	615,23			

TABELA 62. Médias das alturas de plantas nos nove tratamentos utilizados

Tratamento	Dose de N 15 DAE (kg.ha ⁻¹)	Dose de N 35 DAE (kg.ha ⁻¹)	Altura de plantas (cm)	
9	60	60	95,6	a
6	30	60	94,9	a b
5	30	30	94,4	a b
8	60	30	94,2	a b
7	60	0	92,8	a b
3	0	60	91,5	a b c
2	0	30	91,0	b c
4	30	0	88,0	c d
1	0	0	84,6	d

As médias seguidas de pelo menos uma mesma letra não diferiram pelo teste de Tukey ao nível de 5% de probabilidade.

Os tratamentos tiveram efeito significativo sobre a altura das plantas de trigo. A altura das plantas das parcelas submetidas aos tratamentos 1, 2 e 4 foi inferior às demais. Verifica-se que a aplicação da dose de 60 kg de N.ha⁻¹ aos 35 DAE nas parcelas que não haviam recebido adubação aos 15 DAE foi eficiente para que as plantas atingissem altura equivalente àquelas que receberam doses mais elevadas

de N. A adubação com 30 kg de N.ha⁻¹ apenas aos 15 DAE não foi suficiente para as plantas expressarem o seu potencial em termos de altura. Verifica-se ainda que as doses mais elevadas, nas condições desse experimento, não propiciaram aumento significativo da altura das plantas em relação às doses usualmente recomendadas (30 kg de N.ha⁻¹ aos 15 DAE e aos 35 DAE, por exemplo).

COELHO (1997) avaliou o efeito de doses de N e parcelamento em trigo durante dois anos e verificou efeito sobre a altura de plantas em apenas um deles. Entretanto, atribuiu a redução de altura nas doses mais elevadas de N ao acamamento precoce das plantas, o que prejudicou o crescimento e desenvolvimento das mesmas. Nesse trabalho não se verificou acamamento de plantas. SILVA e GOTO (1991) também não verificaram efeito do N sobre a altura de plantas em cultivares de porte baixo, mas também não observaram acamamento de plantas. O cultivar BRS 207, utilizado nesse experimento, é de porte médio e recomendado para cultivo sob irrigação em solos com boa fertilidade, condições que exigem resistência ao acamamento. Sendo assim, acredita-se que um dos motivos pelos quais não se verificou acamamento foi que o cultivar utilizado foi selecionado para altas produtividades e resistência ao acamamento.

Biomassa seca

O resumo da análise de variância para a biomassa seca é apresentado na Tabela 63 e as médias dos tratamentos são apresentadas na Tabela 64. A média geral foi 10.139 kg.ha⁻¹ e o coeficiente de variação 8,47.

TABELA 63. Quadro de análise de variância para biomassa seca nos tratamentos

Fator de variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Tratamento	8	89502473,4	11187809,2	15,15	< 0,0001
Resíduo	35	25847834,9	738509,6		
Total	43	115350308,3			

TABELA 64. Médias da biomassa seca nos nove tratamentos utilizados

Tratamento	Dose de N		Biomassa seca (kg.ha ⁻¹)	
	15 DAE (kg.ha ⁻¹)	35 DAE (kg.ha ⁻¹)		
9	60	60	11.642	a
6	30	60	11.550	a
8	60	30	11.160	a
7	60	0	11.012	a
5	30	30	10.590	a b
3	0	60	9.996	a b c
4	30	0	9.105	b c
2	0	30	8.625	c d
1	0	0	6.925	d

As médias seguidas de pelo menos uma mesma letra não diferiram pelo teste de Tukey ao nível de 5% de probabilidade.

A biomassa seca da cultura foi significativamente influenciada pelos tratamentos utilizados, sendo que as doses mais elevadas propiciaram aumento da mesma. A biomassa nos tratamentos 1, 2 e 4, onde se aplicou a dose total de 30 kg de N.ha⁻¹, foi inferior. Verifica-se que a aplicação da dose de 60 kg de N.ha⁻¹ aos 35 DAE propiciou a produção de biomassa equivalente às doses mais elevadas. Verificou-se que as doses mais elevadas não promoveram produção de biomassa superior às doses tradicionalmente utilizadas. Resultados semelhantes foram obtidos por COELHO (1997) com diferença significativa entre o contraste vs. o fatorial.

Produtividade

O resumo da análise de variância para a produtividade é apresentado na Tabela 65 e as médias dos tratamentos são apresentadas na Tabela 66. A média geral foi 4.368 kg.ha⁻¹ e o coeficiente de variação 7,99.

TABELA 65. Quadro de análise de variância para produtividade nos tratamentos

Fator de variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Tratamento	8	16282866,38	2035358,30	16,73	< 0,0001
Resíduo	35	4259336,76	121695,34		
Total	43	20542203,14			

TABELA 66. Médias da produtividade nos nove tratamentos utilizados

Tratamento	Dose de N		Produtividade (kg.ha ⁻¹)	
	15 DAE (kg.ha ⁻¹)	35 DAE (kg.ha ⁻¹)		
6	30	60	5.075	a
9	60	60	4.886	a
8	30	30	4.813	a
5	60	0	4.636	a b
7	60	30	4.547	a b c
3	0	60	4.380	a b c
4	0	30	3.936	b c
2	30	0	3.850	c
1	0	0	2.897	d

As médias seguidas de pelo menos uma mesma letra não diferiram pelo teste de Tukey ao nível de 5% de probabilidade.

O efeito dos tratamentos sobre a produtividade foi significativo e seguiu o mesmo comportamento dos parâmetros biomassa e altura de plantas. Os tratamentos em que foi aplicada a dose igual ou inferior a 30 kg de N.ha⁻¹ a produtividade foi inferior. A aplicação da dose de 60 kg de N.ha⁻¹, independente da época, foi suficiente para obtenção das maiores produtividades. A aplicação de doses mais elevadas de N poderiam levar a uma redução da produtividade, conforme verificado por PÖTTKER e ROMAN (1998) e SILVA (1991), entretanto esse comportamento não foi observado no presente trabalho. Essa redução poderia ser causada principalmente pelo acamamento de plantas (Marschner, 1986 citado por COELHO, 1997). Além disso COELHO (1997) sugere ainda que, em seu trabalho, nas doses intermediárias de N o índice de colheita e o peso de mil grãos mais elevados contribuíram para a maior produtividade com essas doses. SILVA e GOTO (1991) observaram maior rendimento de grãos, maior número de espiguetas por espigas e baixo índice de acamamento como resposta à adubação nitrogenada em trigo. FRIZZONE et al. (1996) verificaram efeito significativo para irrigação, dose de N e interação desses fatores.

Massa específica

O resumo da análise de variância para a característica massa específica é apresentado na Tabela 67 e as médias dos tratamentos são apresentadas na Tabela 68. A média geral foi 75,42 e o coeficiente de variação 1,17.

TABELA 67. Quadro de análise de variância para massa específica nos tratamentos

Fator de variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Pr > F
Tratamento	8	25,55	3,19	4,06	0,0017
Resíduo	35	27,55	0,79		
Total	43	53,09			

TABELA 68. Médias da massa específica nos nove tratamentos utilizados

Tratamento	Dose de N		Peso hectoítrico	
	15 DAE (kg.ha ⁻¹)	35 DAE (kg.ha ⁻¹)		
1	0	0	77,1	a
4	30	0	76,2	a b
2	0	30	75,8	a b
5	30	30	75,4	a b
8	60	30	75,4	a b
7	60	0	75,2	a b
3	0	60	74,9	b
9	60	60	74,6	b
6	30	60	74,4	b

As médias seguidas de pelo menos uma mesma letra não diferiram pelo teste de Tukey ao nível de 5% de probabilidade.

Houve efeito dos tratamentos sobre a massa específica dos grãos colhidos. COELHO (1997) verificou resposta linear e decrescente com incremento das doses de N, porém atribuiu esse comportamento ao acamamento de plantas. De acordo com esse autor, o acamamento pode proporcionar má formação de grãos, o que confere menor peso a um volume fixo de grãos. Além disso, esse autor verificou correlação negativa entre acamamento de plantas e o peso hectolítrico. Entretanto, nos trabalhos de SILVA e GOTO (1991) e SILVA (1991) não houve efeito do N sobre o peso hectolítrico.

No presente trabalho não se verificou acamamento de plantas, entretanto o comportamento foi similar ao de COELHO (1997), com maior massa específica nas doses mais baixas de N. Acredita-se que esse efeito deve-se à maior produtividade com as doses mais elevadas. FRIZZONE et al. (1996) verificaram efeito do N sobre o número de grãos por espiga e redução do peso hectolítrico com o aumento do nível de N e redução na lâmina de irrigação. O maior número de grãos por espiga pode prejudicar o enchimento dos grãos, devido à competição por fotoassimilados (CÁNOVAS e TRINDADE, 2003).

Índice de colheita

O quadro da análise de variância para o índice de colheita é apresentado na Tabela 69 e as médias dos tratamentos são apresentadas na Tabela 70. A média geral foi 0,38 e o coeficiente de variação 6,24.

TABELA 69. Quadro de análise de variância para índice de colheita nos tratamentos

Fator de variação	Graus de liberdade.	Soma de quadrados	Quadrado médio	F	Pr > F
Tratamento	8	0,178244	0,022280	4,45	0,0009
Resíduo	35	0,175420	0,005012		
Total	43				

TABELA 70. Médias do índice de colheita nos nove tratamentos utilizados

Tratamento	Dose de N		Índice de colheita	
	15 DAE (kg.ha ⁻¹)	35 DAE (kg.ha ⁻¹)		
1	0	0	0,52	a
2	0	30	0,48	a b
4	30	0	0,40	a b c
5	30	30	0,39	a b c
3	0	60	0,36	b c
6	30	60	0,35	b c
9	60	60	0,35	b c
8	60	30	0,34	b c
7	60	0	0,31	c

As médias seguidas de pelo menos uma mesma letra não diferiram pelo teste de Tukey ao nível de 5% de probabilidade.

Verificou-se efeito dos tratamentos sobre o índice de colheita. Os tratamentos que receberam doses mais baixas de N apresentaram maiores índices de colheita. Os tratamentos que receberam as doses mais elevadas na primeira adubação vegetaram mais e a proporção de grãos produzidos em relação à biomassa total foi menor. As plantas de trigo submetidas a doses elevadas de N têm crescimento vegetativo exagerado, podendo ocorrer autossombreamento e acamamento, o que diminui a interceptação da energia luminosa, fotossíntese líquida e produção de fotoassimilados (COELHO, 1997).

5. RESUMO E CONCLUSÕES

Esse trabalho teve como objetivo avaliar a discriminação de doses de nitrogênio em trigo a partir da resposta espectral do dossel no visível e no infravermelho próximo por meio de imagens digitais, associadas ou não a características de textura das imagens do dossel. Avaliou-se ainda a associação de informações de imagens processadas por mais de um índice espectral para o desenvolvimento de classificadores multivariados. A cultura do trigo foi implantada no campo em parcelas com adubação de plantio uniforme e duas adubações em cobertura, aos 15 e aos 35 dias após a emergência (DAE) totalizando cinco doses (0, 30, 60, 90 e 120 kg de N.ha⁻¹). Plantas de trigo foram cultivadas ainda em vasos, submetidas às cinco doses de N aplicadas dois DAE. Imagens foram obtidas em três épocas no campo e em uma época nos vasos, o teor de clorofila nas folhas foi estimado utilizando-se um medidor de clorofila e o teor total de N nas folhas foi determinado em amostras por meio de análise laboratorial. Avaliou-se a relação funcional entre as doses de N aplicadas, os valores SPAD e os valores de N foliar, nas plantas cultivadas no campo e em vasos. A resposta da cultura às doses de nitrogênio utilizadas e ao parcelamento foi avaliada no experimento de campo. Os resultados obtidos permitiram as seguintes conclusões:

- Com a utilização do medidor de clorofila SPAD 502 a discriminação entre as doses de N utilizadas em cobertura no campo, foi possível 29 dias após a emergência, correspondente a 14 dias após a adubação. No experimento em vasos, com a adubação nitrogenada realizada dois dias após a emergência das plantas, uma discriminação adequada utilizando-se os valores SPAD só foi conseguida aos 27 DAE.
- Com a utilização das características extraídas das imagens das parcelas no campo foi possível discriminar as doses de N 23 dias após a emergência da cultura (oito dias após a adubação nitrogenada em cobertura).

- No experimento em vasos a classificação com os valores de N foliar só foi estatisticamente melhor que uma classificação ao acaso 44 dias após a emergência.
- Tanto no experimento em vasos como no experimento no campo verificou-se uma variação nos valores SPAD durante o desenvolvimento das plantas, independente da dose de N utilizada, o que dificulta o estabelecimento de valores SPAD críticos para identificar a deficiência ou suficiência de N independente do estágio de desenvolvimento das plantas.
- Não se verificou ganho em termos de classificação pela associação de características de reflectância e textura em relação à utilização de características de reflectância exclusivamente.
- Não houve diferença estatística entre os classificadores desenvolvidos com as características das imagens, valores SPAD e teores de N foliar aos 44 dias após a emergência nos vasos e aos 35 dias após a emergência no campo.
- Verificou-se benefício, em termos de classificação, pela associação de características extraídas das imagens provenientes do processamento por diferentes índices espectrais. E
- Em geral, foi benéfica a associação de índices que utilizaram a banda verde com índices que utilizaram a vermelha, uma vez que os primeiros relacionam-se com a tonalidade de verde das folhas e os outros com a cobertura do solo.
- A ausência de diferença estatística entre a produtividade das parcelas de trigo submetidas à dose total de 60kg de N.ha⁻¹ em duas épocas de cobertura, indica que é possível identificar e corrigir a deficiência de N durante o ciclo da cultura com os classificadores desenvolvidos.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ADAMSEN, F.J.; PINTER JR ,P.J.; BARNES, E.M.; LAMORTE, R.L; WALL, G.W.; LEAVITT, S.W.; KIMBALL, B.A. Measuring wheat senescence with a digital camera **Crop Science**, Madison, WI, n.39, p.719–724, 1999.

AHMAD, I.S; REID, J.F.; NOGUCHI, N.; HANSEN, A.C **Nitrogen sensing for precision agriculture using chlorophyll maps** ASAE Paper N. 993035, ASAE, St. Joseph, 1999.

ÂNGULO FILHO, R.; CUNHA, C.A.H.; RUDORFF, B.F.T.; MOREIRA, M.A. **Comportamento espectral da cultura do feijão (IAC - carioca 80) irrigado com diferentes lâminas de água**. Anais X SBSR, Foz do Iguaçu, INPE, p. 3-10, 2001.

ARGENTA, G.; SILVA, P.R.F.; BORTOLINI, C.G.; FORSTHOFER, E.L.; STRIEDER, M.L. Relação da leitura do clorofilômetro com os teores de clorofila extraível e de nitrogênio na folha de milho. **Revista Brasileira de Fisiologia Vegetal**, Brasília, v.2 n.13, p.158-167, 2001.

ARGENTA, G.; SILVA, P.R.F.; MIELNICZUK, J.; BORTOLINI, C.G. Parâmetros de planta como indicadores do nível de nitrogênio na cultura do milho. **Pesquisa agropecuária brasileira**, Brasília, v.37 n.4, p. 519-527, 2002.

BAUSCH, W.C.; DUKE, H.R. Remote sensing of plant nitrogen status in corn. **Transactions of the ASAE**, St. Joseph, v.5 n. 39, p.1869-1875, 1996.

BOEGH, E.; SOEGAARDA, H.; BROGEB, N.; HASAGERC, C.B.; JENSENC, N.O.; SCHELDEB , K.; THOMSENB ,A. Airborne multispectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture. **Remote sensing of environment**, New York, n.81, p.179 – 193, 2002.

BORHAN, M.S.; PANIGRAHI, S. **Multi-spectral imaging techniques for nitrogen determination in potato leaf**. ASAE Paper No. 995005, ASAE, St. Joseph, 1999.

CÁNOVAS, A.D; TRINDADE, M.G. **Efeito de níveis de nitrogênio e frequência de aplicação de água na produtividade e na aptidão industrial do trigo**. Santo Antônio de Goiás: Embrapa Arroz e Feijão, 7 p. (Embrapa Arroz e Feijão. Comunicado Técnico, 70), 2003.

CARVALHO, M.A.C.; FURLANI JUNIOR, E.; ARF, O.; SÁ, M.E.; PAULINO, H.B.; BUZETTI, S. Doses e épocas de aplicação de nitrogênio e teores foliares deste

nutriente e de clorofila em feijoeiro. **Revista Brasileira de Ciência do Solo**, Viçosa, n.27, p.445-450, 2003.

CHAPMAN, S.C.; BARRETO, H.J. Using a chlorophyll meter to estimate leaf nitrogen or tropical maize during vegetative growth. **Agronomy Journal**, Madison, n.89, p.557-562, 1997.

COELHO, M.A.O. **Resposta do trigo (*Triticum aestivum* L.) irrigado à adubação nitrogenada em cobertura**. 1997. Tese (Mestrado em fitotecnia) - Universidade Federal de Viçosa, Viçosa. 70p.

COMISSÃO DE PESQUISA DE TRIGO NO BRASIL CENTRAL. **Indicações técnicas para produção de trigo na Região do Brasil Central – Safra 2002**. <http://www.cnpt.embrapa.br/sist-prod/trigo-central02/index.htm> acesso em 06/08/2004.

CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing of environment**, New York, n.37, p.35-46, 1991.

CONGALTON, R.G.; MEAD, R.A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric engineering & remote sensing**, Bethesda, v.49 n.1, p.69-74, 1983.

COSTA, T.C.C. **Avaliação de estratégias para classificação de imagens orbitais em mapeamento de uso e cobertura da terra**. 1999 Tese (doutorado Ciência Florestal) – Universidade Federal de Viçosa: UFV, 109p.

DE MORI, C.; FERREIRA FILHO, A. **Custo de produção de trigo e de aveia: estimativa safra 2003**. Passo Fundo: Embrapa Trigo, 2003. 5 p. html (Embrapa Trigo. Comunicado Técnico Online, 111). Disponível em: http://www.cnpt.embrapa.br/biblio/co/p_co111.htm acesso em 10/10/2004

DIAS, L.E.; BARROS, N.F.; FRANCO, A.A. **Nitrogênio**. Associação Brasileira de Educação Agrícola Superior – ABEAS. 90p. 1996

DIKER, K.; BAUSCH, W. C.; HEERMANN, D. F. **Monitoring temporal changes of irrigated corn by aerial images**. ASAE Meeting Paper No. 01-1144, ASAE, St. Joseph, 2001.

EMBRAPA TRIGO. **Área, produção e produtividade de trigo no mundo, no Brasil e percentuais de participação do Brasil, período 1962/2003** <http://www.cnpt.embrapa.br/economia/> acesso em 10/10/2004.

EPIPHANIO, J.C.N. e FORMAGGIO, A.R. Sensoriamento remoto de três parâmetros agrônômicos de trigo e feijão. **Pesquisa agropecuária brasileira**, Brasília, v.26 n.10, p.1615-1624, 1991.

FERNANDES, M.S.; ROSSIELO, R.O.P. Aspectos do metabolismo e utilização do nitrogênio em gramíneas tropicais. In: MATTOS, H.B.; WERNER, J.C.; YAMADA, T.; MALAVOLTA, E. **Calagem e adubação de pastagens**. Piracicaba: Associação Brasileira para Pesquisa da Potassa e do Fosfato, p. 93-123, 1986.

FREEMAN, K.W.; RAUN, W.R.; JOHNSON G.V., MULLEN, R.W. STONE M.L.; SOLIE, J.B. Late-season prediction of wheat grain yield and grain protein. **Communications in soil science and plant analysis**, New York, v.34 n.13 & 14, p.1837–1852, 2003.

FRIZZONE, J.A.; MELLO JUNIOR, A.V.; FOLEGATTI, M.V.; BOTREL, T.A. Efeito de diferentes níveis de irrigação e adubação nitrogenada sobre componentes de produtividade da cultura do trigo. **Pesquisa agropecuária brasileira**, Brasília, v.31 n.6, p.425-434, 1996.

GHAZANFARI, A.; IRUDAYARAJ, J.; KUSALIK, A.; ROMANIUK, M. Machine vision grading of pistachio nuts using fourier descriptors **Journal of agricultural engineering research**, London, n.68, p.247-252, 1997.

GIL, P.T; FONTES, P.C.R.; CECON, P.R.; FERREIRA, F.A. Índice SPAD para o diagnóstico do estado de nitrogênio e para o prognóstico da produtividade da batata. **Horticultura brasileira**, Brasília, v.20 n.4, p.611-615, 2002.

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**, Oxford, n.39, p.67-93, 2003.

GOMIDE, R.L.; MATTOSO, M.J.; QUEIROZ, D.M.; MANTOVANI, E.C. **Economic Analysis of Precision Agriculture System Under Brazilian Irrigated Field Conditions**. ASAE paper 001015. ASAE, St. Joseph, MI, 2000.

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

GOPALAPILLAI, S.; TIAN, L.; BEAL, J. **Detection of nitrogen stress in corn using digital aerial imaging**. ASAE Meeting Paper No. 983030, ASAE, St. Joseph, 1998.

GUIMARÃES, T.G. **Nitrogênio no solo e na planta, teor de clorofila e produção do tomateiro, no campo e na estufa, influenciados por doses de nitrogênio**. 1998. Tese (Doutorado em fitotecnia) - Universidade Federal de Viçosa, Viçosa. 184p.

GUIMARÃES, T.G.; FONTES, P.C.R.; PEREIRA, P.R.G.; ALVAREZ V.; V.H.; MONNERAT, P.H. Teores de clorofila determinados por medidor portátil e sua relação com formas de nitrogênio em folhas de tomateiro cultivados em dois tipos de solo. **Bragantia**, Campinas, v.58 n.1, p.209-216, 1999

HABOUDANE, D.; MILLER, J.R.; TREMBLAY, N.; ZARCO-TEJADA, P.J., DEXTRAZE, L. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote sensing of environment**, New York, n.81, p.416– 426, 2002.

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.

HINZMAN, L. D.; BAUER, M. E.; DAUGHTRY, C. S. T. Effects of nitrogen fertilization on growth and reflectance characteristics of winter wheat. **Remote sensing of environment**, New York, n.19, p.47-61, 1986.

HOFFMAN, R.; VIEIRA, S. **Análise de regressão: uma introdução à econometria**. Editora HUCITEC: São Paulo, 1983. 379p.

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.

IFA, International Fertilizer Industry Association **Nitrogen fertilizer nutrient consumption**. <http://www.fertilizer.org/ifa/statistics/indicators/tablen.asp> acesso em 10/10/2004.

JAYAS, D.S.; PALIWAL, J.; VISEN, N.S. Multi-layer neural networks for image analysis of agricultural products. **Journal of agricultural engineering research**, London, v.2 n.77, p.119-128, 2000.

JENSEN, J.R. **Introductory digital image processing: a remote sensing perspective** Prentice Hall, New Jersey, 1996. 318p

JOHNSON, R.A.; WICHERN, D.W. **Applied multivariate statistical analysis**. Prentice Hall, New Jersey, 1998. 816p.

KACIRA, M.; LING, P.P.; SHORT, T.H. **Non-contact sensing of plant water stress by ir thermometry and image processing** ASAE paper n. 995004, ASAE, St. Joseph, 1999.

KASSLER, M. Agricultural automation in the new millennium. **Computers and electronics in agriculture**, Oxford, n. 30, p. 237–240, 2001.

KHATTREE, R.; NAIK, D.N. **Multivariate data reduction and discrimination with SAS software**. Cary, NC: SAS Institute Inc., 2000. 558p.

KIRDA, C.; DERICI, M.R.; SCHEPERS, J.S. Yield response and N-fertiliser recovery of rainfed wheat growing in the Mediterranean region. **Field crops research**, Amsterdam, n.71, p.113-122, 2001.

LARSCHEID, G.; BLACKMORE, B. S.; MOORE, M. **Management decisions based on yield maps**. 1st European Conference on Precision Agriculture. 1997.

LAVRES JUNIOR, J. **Combinações de doses de Nitrogênio e Potássio para o Capim-Mombaça**. 2002. Dissertação (Mestrado em Agronomia) - Escola Superior de Agricultura Luís de Queiroz , Universidade de São Paulo, Piracicaba. 103p.

LEEMANS, V.; MAGEIN, H.; DESTAIN, M.F. Defects segmentation on 'Golden Delicious' apples by using colour machine vision **Computers and electronics in agriculture**, Oxford, n.20, p.117–130, 1998.

LOBELL, D.B.; ORTIZ-MONASTERIO, J.I.; ASNER, G.P. Relative importance of soil and climate variability for nitrogen management in irrigated wheat. **Field Crops Research**, Amsterdam, n.87, p.155–165, 2004.

LOPEZ-BELLIDO, R.J.; SHEPHERD, C.E.; BARRACLOUGH, P.B. Predicting post-anthesis N requirements of bread wheat with a Minolta SPAD meter. **European journal of agronomy**, Amsterdam, n.20, p.313–320, 2004.

LOPEZ-CANTARERO, I; LORENTE, F.A.; ROMERO, L. Are chlorophylls good indicators of nitrogen and phosphorus levels? **Journal of plant nutrition**, New York, v.6 n.17, p.979-990, 1994.

LUKINA, E.V., RAUN W.R., STONE M.L., SOLIE J.B., JOHNSON G.V., LEES H.L., LARUFFA J.M., PHILLIPS S.B. **Effect of row spacing, N rate and growth stage on spectral radiance in winter wheat**. OSU Soil Fertility Research Highlights. Oklahoma State University, Department of Plant and Soil Sciences. p. 251-258, 1997.

MALAVOLTA, E.; LIEM, T.H.; PRIMAVESI, A.C.P.A. Exigências nutricionais das plantas forrageiras. In: MATTOS, H.B.; WERNER, J.C.; YAMADA, T.; MALAVOLTA, E. **Calagem e adubação de pastagens**. Piracicaba: Associação Brasileira para Pesquisa da Potassa e do Fosfato, p. 31-76, 1986.

MAPA. **Agricultura Brasileira em Números Anuário 2003**
<http://www.agricultura.gov.br/> acesso em 10/10/2004.

MARTINEZ, H.E.P; CARVALHO, J.G.; SOUZA, R.B. Diagnose foliar. in: RIBEIRO, A.C.; GUIMARÃES, P.T.; ALVAREZ V.,V,H. (ed) **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais 5ª aproximação**.CFSEMG, Viçosa, p 143 - 168, 1999.

MOGES S. M.; RAUN, W. R.; MULLEN, R. W.; FREEMAN K. W.; JOHNSON, G. V., SOLIE, J. B. Evaluation of green, red, and near infrared bands for predicting winter wheat biomass, nitrogen uptake, and final grain yield. **Journal of plant nutrition**, New York, v.27 n.8, p.1431–1441, 2004.

MULLEN, R. W; FREEMAN, K. W, RAUN, W.R.; JOHNSON, G. V.; STONE, M. L.; SOLIE, J. B. Identifying an in-season response index and the potential to increase wheat yield with nitrogen. **Agronomy journal**, Madison, n.95, p. 347–351, 2003.

MURDOCK, L.; JONES, S.; BOWLEY, C.; NEEDHAM, P.; JAMES, J.; HOWE, P. **Using a chlorophyll meter to make nitrogen recommendations on wheat**. Cooperative extension service – University of kentucky , 4p.,1997.

MUTANGA, O.; SKIDMOREA, A.K., WIERENB, S. Discriminating tropical grass (*Cenchrus ciliaris*) canopies grown under different nitrogen treatments using spectroradiometry **Journal of photogrammetry & remote sensing**, Amsterdam, n.57, p.263– 272, 2003.

ORTIZ-MONASTERIO, J.I. Nitrogen management in irrigated spring wheat. In B. CURTIS; S. RAJARAM; GOMEZ MACPHERSON, H. (eds.). **Bread wheat**

improvement and production. FAO Plant Production and Protection Series No. 30, Rome, Italy, p.433-452. 2002.

PINTO, F.A.C.; SENA Jr, D.G.; QUEIROZ, D.M.; GOMIDE, R.L. **Visão artificial na agricultura de precisão.** In: III Simpósio sobre agricultura de precisão, 2001, Piracicaba, Anais... Piracicaba.

PÖTTKER, D.; ROMAN, E.S. Efeito do nitrogênio em trigo cultivado após diferentes sucessões de culturas. **Pesquisa agropecuária brasileira**, Brasília, n. 33, 501-507, 1998.

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, 2000. p. 1-41.

REGAZZI, A.J. **Modelos de regressão não linear e aplicações utilizando o SAS (PROC NLIN)** – 2ª edição. Viçosa: UFV, 2000. 131p.

RIBEIRO JÚNIOR, J.I.; SANTOS, N.T. **INF 260 – Estatística experimental – 1º período letivo de 2004.** Viçosa: UFV, 2004. 169p.

ROSENFELD, G.H.; FITZPATRICK-LINS, K. A coefficient of agreement as a measure of thematic classification accuracy. **Photogrammetric engineering & remote sensing**, Bethesda, v.52 n.2, p.223-227, 1986.

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

SCHEPERS, J.S.; BLACKMER, T.M.; FRANCIS, D.D. Chlorophyll meter method for estimating nitrogen concentration content in plant tissue. In KALRA, Y.P. (ed) **Handbook of reference methods for plant analysis.** p. 129-135. CRC Press, Boca Raton, FL., 1998.

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 Plant Physiology**, Stuttgart, n.148, p.523-529, 1996.

SCHEPERS, J.S.; FRANCIS, D.D.; VIGIL, M.; BELOW, F.E. Comparison of corn leaf nitrogen concentration and chlorophyll meter readings. **Communications in soil science and plant analysis**, New York, v.17-20 n.23, p.2173-2187, 1992.

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.; PINTO, F.A.C.; QUEIROZ, D.M.; VIANA, P.A. Fall armyworm damaged maize plant identification using digital images. **Biosystems engineering**, Oxford, v.4 n.85, p.449-454, 2003.

SÉRÉLÉ, C.Z.; GWYN, Q.H.J.; BOISVERT, J.B.; PATTEY, E.; MCLAUGHLIN, N.; DAOUST, G. **Detection of corn nitrogen status from airborne vis-nir imagery**

using artificial neural networks. Proceeding of the fifth international conference on precision agriculture. ASA-CSSA-SSSA, Madison, WI 53711, 2000.

SILVA, D.B. Efeito do nitrogênio em cobertura sobre o trigo irrigado em sucessão à soja na região dos cerrados. **pesquisa agropecuária brasileira**, Brasília, v.9 n.26, p.1387-1392, 1991.

SILVA, D.B. e GOTO, W.S. Resposta do trigo de sequeiro ao nitrogênio após soja precoce, na região do alto Paranaíba, MG. **pesquisa agropecuária brasileira**, Brasília, v.9 n.26, p.1401-1405, 1991.

SOUZA, M.A.; FRONZA, V. Trigo. in: RIBEIRO, A.C.; GUIMARÃES, P.T.; ALVAREZ V.,V,H. (ed) **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais 5ª aproximação.**, CFSEMG, Viçosa, p 328 - 331, 1999.

STAFFORD, J.V. Implementing precision agriculture in the 21st century. **journal of agricultural engineering research**, London, n.76, p.267-275, 2000.

STEENHOEK, L.; MISRA, M.; HURBURGH JR., C.R.; BERN, C. **Implementing a computer vision system for corn kernel damage evaluation** ASAE Paper n. 99-3199, ASAE, St. Joseph, 1999.

STEHMAN, S.V. Comparison of systematic and random sampling for estimating the accuracy of maps generated from remotely sensed data. **photogrammetric engineering & remote sensing**, Bethesda, v.58 n.9, p.1343-1350, 1992.

STEWART, B.L.; TIAN, L.F. **Real-time machine vision weed-sensing.** ASAE paper 98-3033, ASAE, St. Joseph, 1998.

STONE, M.L., J.B. SOLIE, W.R. RAUN, R.W. WHITNEY, S.L. TAYLOR and J.D. RINGER. Use of spectral radiance for correcting in-season fertilizer nitrogen deficiencies in winter wheat. **Transactions of the ASAE**, St. Joseph, v.5 n.39, p.1623-1631, 1996.

STORY, M.; CONGALTON, R.G. Accuracy assessment: a user's perspective. **Photogrammetric engineering & remote sensing**, Bethesda, v.52 n.3, p.397-399, 1986.

TIAN, L.F.; SLAUGHTER D.C. Environmentally adaptive segmentation algorithm for outdoor image segmentation **Computers and electronics in agriculture**, Oxford n.21, p.153 -168, 1998.

TILLET, N.D.; HAGUE, T.; MILES, S.J. A field assessment of a potential method for weed and crop mapping on the basis of crop planting geometry. **Computers and electronics in agriculture**, Oxford ,n.32, p. 229-246, 2001.

TOU, J.T. e GONZALES, R.C. **Pattern recognition principles:** Addison-Wesley Publishing Company, Reading,.1974. 377p.

TUMBO, S.D.; WAGNER, D.G.; HEINEMANN, P.H. Hyperspectral-based neural network for predicting chlorophyll status in corn. **Transactions of the ASAE**, St. Joseph, v.45 n.3, p.825-832, 2002.

VARELLA, C.A.A.; KHOURY JR., J.K.; PINTO, F.A.C.; FRANÇA, G.E. **Estimativa da deficiência de nitrogênio na cultura do milho utilizando características de imagens digitais para uso em sensoriamento remoto.** Anais XI SBSR, Belo Horizonte, p. 2391 – 2398, 2003.

VARELLA, C.A.A.; PINTO, F.A.C.; QUEIROZ, D.M.; SENA JR, D.G. Determinação da cobertura de solo por análise de imagens e redes neurais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.6 n.2, p.225-229, 2002.

VARVEL, G.E.; SCHEPERS, J.S; FRANCIS, D.D. Ability for in-season correction of nitrogen deficiency in corn using chlorophyll meters. **Soil science society of america journal**, Madison, n. 61, p.1233-1239, 1997.

VIEIRA, C.A.O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study.** 2000. Ph.D. Thesis, University of Nottingham, Nottingham, 323p.

WELSH, J.P.; WOOD, G.A.; GODWIN, R.J.; TAYLOR, J.C.; EARL, R.; BLACKMORE, S.; KNIGHT, S.M. Developing strategies for spatially variable nitrogen application in cereals, part II: wheat. **Biosystems engineering**, Oxford, v.4 n.84, p. 495–511, 2003.

WOOD, G.A.; WELSH, J.P.; GODWIN, R.J.; TAYLOR, J.C.; EARL, R.; KNIGHT, S.M. Real-time measures of canopy size as a basis for spatially varying nitrogen applications to winter wheat sown at different seed rates. **Biosystems engineering**, Oxford, v.4 n.84, p.513–531, 2003.

XU, W; ROSENOW, D.T.; NGUYEN, H.T. Stay green trait in grain sorghum relationship between visual rating and leaf chlorophyll concentration **Plant breeding**, Berlin, n. 119, p.365-367, 2000.

YANG, X; BEYENAL, H.; GARY H.; LEWANDOWSKI, Z. Evaluation of biofilm image thresholding methods. **water research**, London, v. 35, p 1149-1158, 2001.

ZHANG, J.; SOKHANSANJ, S.; WU, S.; FANG, R.; YANG, W. A trainable grading system for tobacco leaves. **Computers and electronics in agriculture**, Oxford, n.16 p. 231–244, 1997.

7. APÊNDICES

Apêndice A

Código-fonte do algoritmo implementado no MATLAB, para processar as imagens das parcelas de trigo, extrair as características de reflectância e textura e salvar dados em arquivo texto

```
% algoritmo para processar imagens do trigo cultivado em parcelas
% calculo das medias e momentos usando comando hist
% indices nao expandidos
% Darly Geraldo de Sena Jr.
% processamento refeito nov/04
%
% camera duncantech
% indices:
%     excesso de verde;
%     razao verde-vermelho;
%     verde normalizado;
%     vermelho normalizado;
%     ndvi;
%     gndvi;
%     razao vermelho/infravermelho;
%     razao verde/infravermelho;e
%     ir+g-r-b;
% salvar caracteristicas:
% media, variancia (2), 3, 4, 5 e 6 momentos do histograma
clear
clc
% carrega imagens
%
[nomearq,caminho] = uigetfile('*.tif','Selecione a data das imagens');
% le os dados
%
% inicializa o contador de linhas do resultado
ct_lin=0;
for p=1:45 % parcelas
    for i=1:3 % imagens das parcelas
        % incrementa o contador de linhas do resultado
        ct_lin=ct_lin+1;
        if i==1
            im='a';
        elseif i==2
            im='b';
        elseif i==3;
            im='c';
        end
        % le as imagens CIR e RGB
        imargb=imread(strcat(caminho,strcat(num2str(p),im),' - rgb.tif'));
        imacir=imread(strcat(caminho,strcat(num2str(p),im),' - cir.tif'));
```

```

% elimina as bordas
imargb=imargb(10:1028,10:1381,:);
imacir=imacir(10:1028,10:1381,:);
% le as bandas e elimina valor zero
% vermelho
r=double(imargb(:,:,1));
if min(r(:))==0
    bin=im2bw(uint8(r),1/255);
    nib=abs(double(bin)-1);
    r=r+nib;
    clear bin nib
end
% verde
g=double(imargb(:,:,2));
if min(g(:))==0
    bin=im2bw(uint8(g),1/255);
    nib=abs(double(bin)-1);
    g=g+nib;
    clear bin nib
end
% azul
b=double(imargb(:,:,3));
if min(b(:))==0
    bin=im2bw(uint8(b),1/255);
    nib=abs(double(bin)-1);
    b=b+nib;
    clear bin nib
end
% infravermelho
ir=double(imacir(:,:,1));
if min(ir(:))==0
    bin=im2bw(uint8(ir),1/255);
    nib=abs(double(bin)-1);
    ir=ir+nib;
    clear bin nib
end
% limpa imagens
clear imargb imacir
%
% excesso de verde
ev=(2.*g-r-b)./(r+g+b); % calcula o indice
[prob nivel]=hist(ev(:),100); % calcula parametros
prob=prob./sum(prob);
media_ev=prob*nivel';
% resultados
resultado(ct_lin,1)=media_ev;
resultado(ct_lin,2)=(nivel-media_ev).^2*prob'; % momento 2
resultado(ct_lin,3)=(nivel-media_ev).^3*prob'; % momento 3
resultado(ct_lin,4)=(nivel-media_ev).^4*prob'; % momento 4
resultado(ct_lin,5)=(nivel-media_ev).^5*prob'; % momento 5
resultado(ct_lin,6)=(nivel-media_ev).^6*prob'; % momento 6
% limpa variaveis desnecessarias
clear ev prob nivel media_ev
%
% razao verde vermelho
vdvm=g./r; % calcula o indice
[prob nivel]=hist(vdvm(:),100); % calcula parametros
prob=prob./sum(prob);
media_vdvm=prob*nivel';
% resultados
resultado(ct_lin,7)=media_vdvm;

```

```

resultado(ct_lin,8)=(nivel-media_vdvm).^2*prob'; % momento 2
resultado(ct_lin,9)=(nivel-media_vdvm).^3*prob'; % momento 3
resultado(ct_lin,10)=(nivel-media_vdvm).^4*prob'; % momento 4
resultado(ct_lin,11)=(nivel-media_vdvm).^5*prob'; % momento 5
resultado(ct_lin,12)=(nivel-media_vdvm).^6*prob'; % momento 6
% limpa variaveis desnecessarias
clear vdvm prob nivel media_vdvm
%
% verde normalizado
vdm=(g./(r+g+b)); % calcula o indice
[prob nivel]=hist(vdm(:,100)); % calcula parametros
prob=prob./sum(prob);
media_vdm=prob*nivel';
% resultados
resultado(ct_lin,13)=media_vdm;
resultado(ct_lin,14)=(nivel-media_vdm).^2*prob'; % momento 2
resultado(ct_lin,15)=(nivel-media_vdm).^3*prob'; % momento 3
resultado(ct_lin,16)=(nivel-media_vdm).^4*prob'; % momento 4
resultado(ct_lin,17)=(nivel-media_vdm).^5*prob'; % momento 5
resultado(ct_lin,18)=(nivel-media_vdm).^6*prob'; % momento 6
% limpa variaveis desnecessarias
clear vdm prob nivel media_vdm
%
% vermelho normalizado
vmn=(r./(r+g+b)); % calcula o indice
[prob nivel]=hist(vmn(:,100)); % calcula parametros
prob=prob./sum(prob);
media_vmn=prob*nivel';
% resultados
resultado(ct_lin,19)=media_vmn;
resultado(ct_lin,20)=(nivel-media_vmn).^2*prob'; % momento 2
resultado(ct_lin,21)=(nivel-media_vmn).^3*prob'; % momento 3
resultado(ct_lin,22)=(nivel-media_vmn).^4*prob'; % momento 4
resultado(ct_lin,23)=(nivel-media_vmn).^5*prob'; % momento 5
resultado(ct_lin,24)=(nivel-media_vmn).^6*prob'; % momento 6
% limpa variaveis desnecessarias
clear vmn prob nivel media_vmn
%
% NDVI
ndvi=(ir-r)./(ir+r); % calcula o indice
[prob nivel]=hist(ndvi(:,100)); % calcula parametros
prob=prob./sum(prob);
media_ndvi=prob*nivel';
% resultados
resultado(ct_lin,25)=media_ndvi;
resultado(ct_lin,26)=(nivel-media_ndvi).^2*prob'; % momento 2
resultado(ct_lin,27)=(nivel-media_ndvi).^3*prob'; % momento 3
resultado(ct_lin,28)=(nivel-media_ndvi).^4*prob'; % momento 4
resultado(ct_lin,29)=(nivel-media_ndvi).^5*prob'; % momento 5
resultado(ct_lin,30)=(nivel-media_ndvi).^6*prob'; % momento 6
% limpa variaveis desnecessarias
clear ndvi prob nivel media_ndvi_e
%
% GNDVI
gndvi=(ir-g)./(ir+g); % calcula o indice
[prob nivel]=hist(gndvi(:,100)); % calcula parametros
prob=prob./sum(prob);
media_gndvi=prob*nivel';
% resultados
resultado(ct_lin,31)=media_gndvi;
resultado(ct_lin,32)=(nivel-media_gndvi).^2*prob'; % momento 2

```

```

resultado(ct_lin,33)=(nivel-media_gndvi).^3*prob';%momento 3
resultado(ct_lin,34)=(nivel-media_gndvi).^4*prob';%momento 4
resultado(ct_lin,35)=(nivel-media_gndvi).^5*prob';%momento 5
resultado(ct_lin,36)=(nivel-media_gndvi).^6*prob';%momento 6
% limpa variaveis desnecessarias
clear gndvi prob nivel media_gndvi
%
% razao vermelho infravermelho
rir=r./ir; % calcula o indice
[prob nivel]=hist(rir(:),100); % calcula parametros
prob=prob./sum(prob);
media_rir=prob*nivel';
% resultados
resultado(ct_lin,37)=media_rir;
resultado(ct_lin,38)=(nivel-media_rir).^2*prob'; % momento 2
resultado(ct_lin,39)=(nivel-media_rir).^3*prob'; % momento 3
resultado(ct_lin,40)=(nivel-media_rir).^4*prob'; % momento 4
resultado(ct_lin,41)=(nivel-media_rir).^5*prob'; % momento 5
resultado(ct_lin,42)=(nivel-media_rir).^6*prob'; % momento 6
% limpa variaveis desnecessarias
clear rir prob nivel media_rir
%
% razao verde infravermelho
gir=g./ir; % calcula o indice
[prob nivel]=hist(gir(:),100); % calcula parametros
prob=prob./sum(prob);
media_gir=prob*nivel';
% resultados
resultado(ct_lin,43)=media_gir;
resultado(ct_lin,44)=(nivel-media_gir).^2*prob'; % momento 2
resultado(ct_lin,45)=(nivel-media_gir).^3*prob'; % momento 3
resultado(ct_lin,46)=(nivel-media_gir).^4*prob'; % momento 4
resultado(ct_lin,47)=(nivel-media_gir).^5*prob'; % momento 5
resultado(ct_lin,48)=(nivel-media_gir).^6*prob'; % momento 6
% limpa variaveis desnecessarias
clear gir prob nivel media_gir
%
%ir+g-r-b;
irgrb=(ir+g-r-b)./(ir+r+g+b); % calcula o indice
[prob nivel]=hist(irgrb(:),100); % calcula parametros
prob=prob./sum(prob);
media_irgrb=prob*nivel';
% resultados
resultado(ct_lin,49)=media_irgrb;
resultado(ct_lin,50)=(nivel-media_irgrb).^2*prob';%momento 2
resultado(ct_lin,51)=(nivel-media_irgrb).^3*prob';%momento 3
resultado(ct_lin,52)=(nivel-media_irgrb).^4*prob';%momento 4
resultado(ct_lin,53)=(nivel-media_irgrb).^5*prob';%momento 5
resultado(ct_lin,54)=(nivel-media_irgrb).^6*prob';%momento 6
% limpa variaveis desnecessarias
clear irgrb prob nivel media_irgrb_e
%
resultado(ct_lin,55)=p;
resultado(ct_lin,56)=i;
% apresenta imagem processada
disp(strcat('imagem.',num2str(ct_lin)))
end
end
% salva resultados
nome_salva=strcat('res_trigo_campo_',caminho(47:50),'.txt');
dlmwrite(nome_salva,resultado,'\t')

```

Apêndice B

Código-fonte do algoritmo implementado no MATLAB, para processar as imagens do trigo cultivado em vasos e calcular a media dos valores dos pixels nas imagens

índice

```
% algoritmo para processar imagens do trigo em vasos
% calculo das medias dos pixels
% nove imagens indice
% camera duncantech
%
% indices:
%   excesso de verde;
%   razao verde-vermelho;
%   verde normalizado;
%   vermelho normalizado;
%   ndvi;
%   gndvi;
%   razao vermelho/infravermelho;
%   razao verde/infravermelho;e
%   ir+g-r-b;
%
% Darly Geraldo de Sena Jr.
% novembro 2004
%
clear
clc
% carrega imagens
[nomearq,caminho] = uigetfile('*.tif','Selecione a data das imagens');
% inicializa o contador de linhas do resultado
ct_lin=0;
for p=1:25 % vasos
    % incrementa o contador de linhas do resultado
    ct_lin=ct_lin+1;
    % le as imagens CIR e RGB
    imargb=imread(strcat(caminho,strcat(num2str(p)),' - rgb.tif'));
    imacir=imread(strcat(caminho,strcat(num2str(p)),' - cir.tif'));
    % elimina as bordas
    imargb=imargb(10:1028,10:1381,:);
    imacir=imacir(10:1028,10:1381,:);
    % le as bandas e elimina valor zero
    % vermelho
    r=double(imargb(:,:,1));
    if min(r(:))==0
        bin=im2bw(uint8(r),1/255);
        nib=abs(double(bin)-1);
        r=r+nib;
        clear bin nib
    end
    % verde
    g=double(imargb(:,:,2));
    if min(g(:))==0
        bin=im2bw(uint8(g),1/255);
        nib=abs(double(bin)-1);
        g=g+nib;
        clear bin nib
    end
end
```

```

% azul
b=double(imargb(:,:,3));
if min(b(:))==0
    bin=im2bw(uint8(b),1/255);
    nib=abs(double(bin)-1);
    b=b+nib;
    clear bin nib
end
% infravermelho
ir=double(imacir(:,:,1));
if min(ir(:))==0
    bin=im2bw(uint8(ir),1/255);
    nib=abs(double(bin)-1);
    ir=ir+nib;
    clear bin nib
end
% limpa imagens
clear imargb imacir
%
% excesso de verde
ev=(2.*g-r-b)./(r+g+b); % calcula o indice
media_ev=mean(nonzeros(ev(:)));
% resultados
resultado(ct_lin,1)=media_ev;
% limpa variaveis desnecessarias
clear ev prob nivel media_ev
%
% razao verde vermelho
vdvm=g./r; % calcula o indice
media_vdvm=mean(nonzeros(vdvm(:)));
% resultados
resultado(ct_lin,2)=media_vdvm;
% limpa variaveis desnecessarias
clear vdvm prob nivel media_vdvm
%
% verde normalizado
vdn=(g./(r+g+b)); % calcula o indice
media_vdn=mean(nonzeros(vdn(:)));
% resultados
resultado(ct_lin,3)=media_vdn;
% limpa variaveis desnecessarias
clear vdn prob nivel media_vdn
%
% vermelho normalizado
vmn=(r./(r+g+b)); % calcula o indice
media_vmn=mean(nonzeros(vmn(:)));
% resultados
resultado(ct_lin,4)=media_vmn;
% limpa variaveis desnecessarias
clear vmn prob nivel media_vmn
%
% NDVI
ndvi=(ir-r)./(ir+r); % calcula o indice
media_ndvi=mean(nonzeros(ndvi(:)));
% resultados
resultado(ct_lin,5)=media_ndvi;
% limpa variaveis desnecessarias
clear ndvi prob nivel media_ndvi_e
%
% GNDVI
gndvi=(ir-g)./(ir+g); % calcula o indice

```

```

media_gndvi=mean(nonzeros(gndvi(:)));
% resultados
resultado(ct_lin,6)=media_gndvi;
% limpa variaveis desnecessarias
clear gndvi prob nivel media_gndvi
%
% razao vermelho infravermelho
rir=r./ir; % calcula o indice
media_rir=mean(nonzeros(rir(:)));
% resultados
resultado(ct_lin,7)=media_rir;
% limpa variaveis desnecessarias
clear rir prob nivel media_rir
%
% razao verde infravermelho
gir=g./ir; % calcula o indice
media_gir=mean(nonzeros(gir(:)));

% resultados
resultado(ct_lin,8)=media_gir;
% limpa variaveis desnecessarias
clear gir prob nivel media_gir
%
%ir+g-r-b;
irgrb=(ir+g-r-b)./(ir+r+g+b); % calcula o indice
media_irgrb=mean(nonzeros(irgrb(:)));

% resultados
resultado(ct_lin,9)=media_irgrb;
% limpa variaveis desnecessarias
clear irgrb prob nivel media_irgrb_e
%
resultado(ct_lin,10)=p;
% apresenta imagem processada
disp(strcat('imagem.',num2str(ct_lin)))
end
% salva resultados
nome_salva=strcat('res_duncan_estufa2_toda.txt');
dlmwrite(nome_salva,resultado,'\t')

```

Apêndice C

Código-fonte do algoritmo implementado no MATLAB, para processar as imagens do trigo cultivado em vasos e calcular a media dos valores dos pixels representando folhas nas imagens índice

```
% algoritmo para processar imagens do trigo em vasos
% calculo das medias dos pixels representando folhas
% nove imagens indice
% camera duncantech
%
% indices:
%   excesso de verde;
%   razao verde-vermelho;
%   verde normalizado;
%   vermelho normalizado;
%   ndvi;
%   gndvi;
%   razao vermelho/infravermelho;
%   razao verde/infravermelho;e
%   ir+g-r-b;
%
% Darly Geraldo de Sena Jr.
% novembro 2004
%
clear
clc
% carrega imagens
[nomearq,caminho] = uigetfile('*.tif','Selecione a data das imagens');
% inicializa o contador de linhas do resultado
ct_lin=0;
for p=1:25 % vasos
    % incrementa o contador de linhas do resultado
    ct_lin=ct_lin+1;
    % le as imagens CIR e RGB
    imargb=imread(strcat(caminho,strcat(num2str(p),' - rgb.tif'));
    imacir=imread(strcat(caminho,strcat(num2str(p),' - cir.tif'));
    % elimina as bordas
    imargb=imargb(10:1028,10:1381,:);
    imacir=imacir(10:1028,10:1381,:);
    % le as bandas e elimina valor zero
    % vermelho
    r=double(imargb(:,:,1));
    if min(r(:))==0
        bin=im2bw(uint8(r),1/255);
        nib=abs(double(bin)-1);
        r=r+nib;
        clear bin nib
    end
    % verde
    g=double(imargb(:,:,2));
    if min(g(:))==0
        bin=im2bw(uint8(g),1/255);
        nib=abs(double(bin)-1);
        g=g+nib;
        clear bin nib
    end
end
```

```

% azul
b=double(imargb(:,:,3));
if min(b(:))==0
    bin=im2bw(uint8(b),1/255);
    nib=abs(double(bin)-1);
    b=b+nib;
    clear bin nib
end
% infravermelho
ir=double(imacir(:,:,1));
if min(ir(:))==0
    bin=im2bw(uint8(ir),1/255);
    nib=abs(double(bin)-1);
    ir=ir+nib;
    clear bin nib
end
% retira fundo
ndvi=(ir-r)/(ir+r); % calcula o indice
ndvi2=uint8((ndvi-min(ndvi(:)))*255/(max(ndvi(:))-min(ndvi(:))));
objt=double(limiterativo(ndvi2));
% limpa imagens
clear imargb imacir
%
% excesso de verde
ev=(2.*g-r-b)/(r+g+b); % calcula o indice
ev=ev.*objt;
media_ev=mean(nonzeros(ev(:)));
% resultados
resultado(ct_lin,1)=media_ev;
% limpa variaveis desnecessarias
clear ev prob nivel media_ev
%
% razao verde vermelho
vdvm=g./r; % calcula o indice
vdvm=vdvm.*objt;
media_vdvm=mean(nonzeros(vdvm(:)));
% resultados
resultado(ct_lin,2)=media_vdvm;
% limpa variaveis desnecessarias
clear vdvm prob nivel media_vdvm
%
% verde normalizado
vdn=(g/(r+g+b)); % calcula o indice
vdn=vdn.*objt;
media_vdn=mean(nonzeros(vdn(:)));
% resultados
resultado(ct_lin,3)=media_vdn;
% limpa variaveis desnecessarias
clear vdn prob nivel media_vdn
%
% vermelho normalizado
vmn=(r/(r+g+b)); % calcula o indice
vmn=vmn.*objt;
media_vmn=mean(nonzeros(vmn(:)));
% resultados
resultado(ct_lin,4)=media_vmn;
% limpa variaveis desnecessarias
clear vmn prob nivel media_vmn
%
% NDVI
ndvi=(ir-r)/(ir+r); % calcula o indice

```

```

ndvi=ndvi.*objt;
media_ndvi=mean(nonzeros(ndvi(:)));
% resultados
resultado(ct_lin,5)=media_ndvi;
% limpa variaveis desnecessarias
clear ndvi prob nivel media_ndvi_e
%
% GNDVI
gndvi=(ir-g)./(ir+g); % calcula o indice
gndvi=gndvi.*objt;
media_gndvi=mean(nonzeros(gndvi(:)));
% resultados
resultado(ct_lin,6)=media_gndvi;
% limpa variaveis desnecessarias
clear gndvi prob nivel media_gndvi
%
% razao vermelho infravermelho
rir=r./ir; % calcula o indice
rir=rir.*objt;
media_rir=mean(nonzeros(rir(:)));
% resultados
resultado(ct_lin,7)=media_rir;
% limpa variaveis desnecessarias
clear rir prob nivel media_rir
%
% razao verde infravermelho
gir=g./ir; % calcula o indice
gir=gir.*objt;
media_gir=mean(nonzeros(gir(:)));

% resultados
resultado(ct_lin,8)=media_gir;
% limpa variaveis desnecessarias
clear gir prob nivel media_gir
%
%ir+g-r-b;
irgrb=(ir+g-r-b)./(ir+r+g+b); % calcula o indice
irgrb=irgrb.*objt;
media_irgrb=mean(nonzeros(irgrb(:)));

% resultados
resultado(ct_lin,9)=media_irgrb;
% limpa variaveis desnecessarias
clear irgrb prob nivel media_irgrb_e
%
resultado(ct_lin,10)=p;
% apresenta imagem processada
disp(strcat('imagem.',num2str(ct_lin)))
end
% salva resultados
nome_salva=strcat('res_duncan_estufa2_objt.txt');
dlmwrite(nome_salva,resultado,'\t')

```

Apêndice D

Código-fonte do algoritmo implementado no MATLAB, para processar as imagens do trigo cultivado em vasos e calcular a media dos valores de todos os pixels e dos pixels representando folhas em cada banda

```
% algoritmo para processar imagens do trigo cultivado em vasos
% calculo da media dos valores de pixels nas bandas
% media de toda a imagem e media dos pixels representando folhas
% camera duncantech
%
% Darly Geraldo de Sena Jr.
% novembro 2004
%
clear
clc
% carrega imagens
%
[nomearq,caminho] = uigetfile('*.tif','Selecione a data das imagens');
% le os dados
%
% inicializa o contador de linhas do resultado
ct_lin=0;
for p=1:25 % vasos
    % incrementa o contador de linhas do resultado
    ct_lin=ct_lin+1;
    % le as imagens CIR e RGB
    imargb=imread(strcat(caminho,strcat(num2str(p),' - rgb.tif'));
    imacir=imread(strcat(caminho,strcat(num2str(p),' - cir.tif'));
    % elimina as bordas
    imargb=imargb(10:1028,10:1381,:);
    imacir=imacir(10:1028,10:1381,:);
    % le as bandas e elimina valor zero
    % vermelho
    r=double(imargb(:,:,1));
    if min(r(:))==0
        bin=im2bw(uint8(r),1/255);
        nib=abs(double(bin)-1);
        r=r+nib;
        clear bin nib
    end
    % verde
    g=double(imargb(:,:,2));
    if min(g(:))==0
        bin=im2bw(uint8(g),1/255);
        nib=abs(double(bin)-1);
        g=g+nib;
        clear bin nib
    end
    % azul
    b=double(imargb(:,:,3));
    if min(b(:))==0
        bin=im2bw(uint8(b),1/255);
        nib=abs(double(bin)-1);
        b=b+nib;
        clear bin nib
    end
end
```

```

% infravermelho
ir=double(imacir(:,:,1));
if min(ir(:))==0
    bin=im2bw(uint8(ir),1/255);
    nib=abs(double(bin)-1);
    ir=ir+nib;
    clear bin nib
end
rt_m=mean(r(:));
gt_m=mean(g(:));
bt_m=mean(b(:));
irt_m=mean(ir(:));

% retira fundo
ndvi=(ir-r)./(ir+r); % calcula o indice
ndvi2=uint8((ndvi-min(ndvi(:)))*255./(max(ndvi(:))-min(ndvi(:))));
objt=double(limiterativo(ndvi2));
ro=r.*objt;
go=g.*objt;
bo=b.*objt;
iro=ir.*objt;
% media sem fundo
ro_m=mean(nonzeros(ro(:)));
go_m=mean(nonzeros(go(:)));
bo_m=mean(nonzeros(bo(:)));
iro_m=mean(nonzeros(iro(:)));

% limpa imagens
clear imargb imacir
%
%
resultado(ct_lin,1)=p;
resultado(ct_lin,2)=rt_m;
resultado(ct_lin,3)=gt_m;
resultado(ct_lin,4)=bt_m;
resultado(ct_lin,5)=irt_m;
resultado(ct_lin,6)=ro_m;
resultado(ct_lin,7)=go_m;
resultado(ct_lin,8)=bo_m;
resultado(ct_lin,9)=iro_m;

% apresenta imagem processada
disp(strcat('imagem.',num2str(ct_lin)))

% end
end

% salva resultados
nome_salva=strcat('dados_duncan_estufa2_pixel.txt');
dlmwrite(nome_salva,resultado,'\t')

```

Apêndice E

Código-fonte do algoritmo implementado no MATLAB para elaborar e avaliar classificadores estatísticos com todas as combinações dos valores médios dos pixels nas imagens índice. Dados obtidos a partir das imagens do trigo cultivado em parcelas. Salvar a exatidão global, coeficiente kappa e matriz de contigência em arquivo texto.

```
% algoritmo para elaboracao e avaliacao de classificador estatistico
% validacao cruzada
% 3 doses de N em trigo cultivado em parcelas
% Darly Geraldo de Sena Jr., julho 2004.
%
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
        contin=zeros(3,3);
        % calcula dados para elaboracao do classificador
        for nc=1:size(mat_vez,1)
            conta_0=1;
            conta_30=1;
            conta_60=1;
            for c=1:size(mat_vez,1)
                if c ~= nc
                    if parc(c,1)==0;
                        mat_0(conta_0,:)=mat_vez(c,:);
                        conta_0=conta_0+1;
                    elseif parc(c,1)==30;
                        mat_30(conta_30,:)=mat_vez(c,:);
                        conta_30=conta_30+1;
                    elseif parc(c,1)==60;
                        mat_60(conta_60,:)=mat_vez(c,:);
                        conta_60=conta_60+1;
                    end
                end
            end
        end
    end
end
```

```

        end
    end
    end % c=1:size(mat_vez,1)
        % calcula media e matriz de covariancia
        med_0=mean(mat_0);
        med_30=mean(mat_30);
        med_60=mean(mat_60);
        cov_0=cov(mat_0);
        cov_30=cov(mat_30);
        cov_60=cov(mat_60);
        % calcula os "d's"
        d0=-0.5*(mat_vez(nc,:)'-
med_0')'*inv(cov_0)*(mat_vez(nc,:)'-med_0')-0.5*log(det(cov_0));
        d30=-0.5*(mat_vez(nc,:)'-
med_30')'*inv(cov_30)*(mat_vez(nc,:)'-med_30')-0.5*log(det(cov_30));
        d60=-0.5*(mat_vez(nc,:)'-
med_60')'*inv(cov_60)*(mat_vez(nc,:)'-med_60')-0.5*log(det(cov_60));
        % "escolhe" o maior "d"
        [dmax,classe]=max([d0;d30;d60]);
        % monta a matriz de erros
        if parc(nc,1)==0 & classe==1
            contin(1,1)=contin(1,1)+1;
        elseif parc(nc,1)==0 & classe==2
            contin(1,2)=contin(1,2)+1;
        elseif parc(nc,1)==0 & classe==3
            contin(1,3)=contin(1,3)+1;
        elseif parc(nc,1)==30 & classe==1
            contin(2,1)=contin(2,1)+1;
        elseif parc(nc,1)==30 & classe==2
            contin(2,2)=contin(2,2)+1;
        elseif parc(nc,1)==30 & classe==3
            contin(2,3)=contin(2,3)+1;
        elseif parc(nc,1)==60 & classe==1
            contin(3,1)=contin(3,1)+1;
        elseif parc(nc,1)==60 & classe==2
            contin(3,2)=contin(3,2)+1;
        elseif parc(nc,1)==60 & classe==3
            contin(3,3)=contin(3,3)+1;
        end
        % limpa as matrizes da validacao cruzada
        clear mat_0 mat_30 mat_60
    end % nc=1:size(mat_vez,1)
        [kappa,var_kappa]=kappa_certo(contin);
        % armazena kappa e var_kappa
        res_kappa(tot_comb,1:size(comb_vez,2))=comb_vez;
        res_kappa(tot_comb,10)=trace(contin)/sum(sum(contin));
        res_kappa(tot_comb,11)=kappa;
        res_kappa(tot_comb,12)=var_kappa;
        res_kappa(tot_comb,13:15)=contin(1,1:3);
        res_kappa(tot_comb,16:18)=contin(2,1:3);
        res_kappa(tot_comb,19:21)=contin(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 F

Código-fonte do algoritmo implementado no MATLAB para elaborar e avaliar classificadores estatísticos com combinações dos valores médios dos pixels nas imagens índice e características de textura. Dados obtidos a partir das imagens do trigo cultivado em parcelas. Salvar a exatidão global, coeficiente kappa e matriz de contigência em arquivo texto.

```
% algoritmo para elaboracao e avaliacao de classificador estatistico
% validacao cruzada
% Dados padronizados, combinacao ate 6 indices
% 3 doses de N em trigo cultivado em parcelas
%
% Darly Sena Jr., julho-novembro 2004.
%
clear
clc
% carrega os dados

[nomearq,caminho] = uigetfile('*.txt','Selecione dados de origem');
dados=dlmread(strcat(caminho,nomearq));
parc=dados(:,1);
% matriz com dados
mat_o=dados(:,2:size(dados,2));
% padroniza os dados: (x-m)/desvio
medm=mean(mat_o);
med_rep=repmat(medm,size(mat_o,1),1);
desv=std(mat_o);
desv_rep=repmat(desv,size(mat_o,1),1);
mat_padr=(mat_o-med_rep)./desv_rep;
mat=mat_padr;
% elimina variaveis desnecessarias
clear medm med_rep desv desv_rep mat_padr;
% calcula as combinacoes
indices=size(mat,2)/6;
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;
tic
for n=1:6;
    comb=combnk(v,n);
    disp(n);
    % monta a matriz com a combinacao da vez
    for i=1:size(comb,1) % 1 a 6 ;
        comb_vez=comb(i,:);
        posicao=1;
        tot_comb=tot_comb+1;
        for k=1:size(comb_vez,2)
            p=comb_vez(k);
            mat_vez(:,posicao:posicao+5)=mat(:,6*p-5:6*p);
            posicao=posicao+6;
        end
    end
end
```

```

% classificador
% *****
    contin=zeros(3,3);
% calcula dados para elaboracao do classificador
% inicializa contador das classes
% monta a matriz de cada classe para leave-one-out(loo)
    for nc=1:size(mat_vez,1)
        conta_0=1;
        conta_30=1;
        conta_60=1;
        for c=1:size(mat_vez,1)
            if c ~= nc
                if parc(c,1)==0;
                    mat_0(conta_0,:)=mat_vez(c,:);
                    conta_0=conta_0+1;
                elseif parc(c,1)==30;
                    mat_30(conta_30,:)=mat_vez(c,:);
                    conta_30=conta_30+1;
                elseif parc(c,1)==60;
                    mat_60(conta_60,:)=mat_vez(c,:);
                    conta_60=conta_60+1;
                end
            end
        end % c=1:size(mat_vez,1)
        % calcula media e matriz de covariancia
        med_0=mean(mat_0);
        med_30=mean(mat_30);
        med_60=mean(mat_60);
        cov_0=cov(mat_0);
        cov_30=cov(mat_30);
        cov_60=cov(mat_60);
        % calcula os "d's"
        d0=-0.5*(mat_vez(nc,:)'-
med_0')'*inv(cov_0)*(mat_vez(nc,:)'-med_0')-0.5*log(det(cov_0));
        d30=-0.5*(mat_vez(nc,:)'-
med_30')'*inv(cov_30)*(mat_vez(nc,:)'-med_30')-0.5*log(det(cov_30));
        d60=-0.5*(mat_vez(nc,:)'-
med_60')'*inv(cov_60)*(mat_vez(nc,:)'-med_60')-0.5*log(det(cov_60));
        % "escolhe" o maior "d"
        [dmax,classe]=max([d0;d30;d60]);
        % monta a matriz de erros
        if parc(nc,1)==0 & classe==1
            contin(1,1)=contin(1,1)+1;
        elseif parc(nc,1)==0 & classe==2
            contin(1,2)=contin(1,2)+1;
        elseif parc(nc,1)==0 & classe==3
            contin(1,3)=contin(1,3)+1;
        elseif parc(nc,1)==30 & classe==1
            contin(2,1)=contin(2,1)+1;
        elseif parc(nc,1)==30 & classe==2
            contin(2,2)=contin(2,2)+1;
        elseif parc(nc,1)==30 & classe==3
            contin(2,3)=contin(2,3)+1;
        elseif parc(nc,1)==60 & classe==1
            contin(3,1)=contin(3,1)+1;
        elseif parc(nc,1)==60 & classe==2
            contin(3,2)=contin(3,2)+1;
        elseif parc(nc,1)==60 & classe==3
            contin(3,3)=contin(3,3)+1;
        end
        % limpa as matrizes da validacao cruzada

```

```

        clear mat_0 mat_30 mat_60
        % *****
    end % nc=1:size(mat_vez,1)
        [kappa,var_kappa]=kappa_certo(contin);
    % armazena EG, kappa, var_kappa e matriz de contingencia
    res_kappa(tot_comb,1:size(comb_vez,2))=comb_vez;
    res_kappa(tot_comb,10)=trace(contin)/sum(sum(contin));
    res_kappa(tot_comb,11)=kappa;
    res_kappa(tot_comb,12)=var_kappa;
    res_kappa(tot_comb,13:15)=contin(1,1:3);
    res_kappa(tot_comb,16:18)=contin(2,1:3);
    res_kappa(tot_comb,19:21)=contin(3,1:3);
    %
    % *****
    % passa para a proxima combinacao
    clear mat_vez
    end % i=1:size(comb,1)
end % n=1:indices;
toc
    nome_salva=(strcat('res_md_mm_padr_',nomearq(size(nomearq,2)-
8:size(nomearq,2))))
    dlmwrite(nome_salva,res_kappa,'\t');
    dlmwrite(nome_salva,res_kappa,'\t');

```

Apêndice G

Código-fonte do algoritmo implementado no MATLAB para elaborar e avaliar classificadores estatísticos com combinações dos valores médios dos pixels nas imagens índice. Dados obtidos a partir das imagens do trigo cultivado em vasos. Salvar a exatidão global, coeficiente kappa e matriz de contigência em arquivo texto.

```
% algoritmo para elaboracao e avaliacao de classificador estatistico
% validacao cruzada
% 5 doses de N em trigo cultivado em vasos
%
% Darly Geraldo de Sena Jr., novembro 2004.
%
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)-1);
% 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;
tic
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
        % classificador
        % *****
        contin=zeros(5,5);
        % calcula dados para elaboracao do classificador
        % inicializa contador das classes
        % monta a matriz de cada classe para leave-one-out(loo)
        for nc=1:size(mat_vez,1)
            conta_0=1;
            conta_30=1;
            conta_60=1;
            conta_90=1;
            conta_120=1;
            for c=1:size(mat_vez,1)
                if c ~= nc
                    if parc(c,1)==0;
```

```

        mat_0(conta_0,:)=mat_vez(c,:);
        conta_0=conta_0+1;
    elseif parc(c,1)==30;
        mat_30(conta_30,:)=mat_vez(c,:);
        conta_30=conta_30+1;
    elseif parc(c,1)==60;
        mat_60(conta_60,:)=mat_vez(c,:);
        conta_60=conta_60+1;
    elseif parc(c,1)==90;
        mat_90(conta_90,:)=mat_vez(c,:);
        conta_90=conta_90+1;
    elseif parc(c,1)==120;
        mat_120(conta_120,:)=mat_vez(c,:);
        conta_120=conta_120+1;
    end
end
end % c=1:size(mat_vez,1)
    % calcula media e matriz de covariancia
med_0=mean(mat_0);
    med_30=mean(mat_30);
    med_60=mean(mat_60);
    med_90=mean(mat_90);
    med_120=mean(mat_120);
    cov_0=cov(mat_0);
    cov_30=cov(mat_30);
    cov_60=cov(mat_60);
    cov_90=cov(mat_90);
    cov_120=cov(mat_120);
    % calcula os "d's"
d0=-0.5*(mat_vez(nc,:))'-
med_0')'*inv(cov_0)*(mat_vez(nc,:))'-med_0')-0.5*log(det(cov_0));
d30=-0.5*(mat_vez(nc,:))'-
med_30')'*inv(cov_30)*(mat_vez(nc,:))'-med_30')-0.5*log(det(cov_30));
d60=-0.5*(mat_vez(nc,:))'-
med_60')'*inv(cov_60)*(mat_vez(nc,:))'-med_60')-0.5*log(det(cov_60));
d90=-0.5*(mat_vez(nc,:))'-
med_90')'*inv(cov_90)*(mat_vez(nc,:))'-med_90')-0.5*log(det(cov_90));
d120=-0.5*(mat_vez(nc,:))'-
med_120')'*inv(cov_120)*(mat_vez(nc,:))'-med_120')-0.5*log(det(cov_120));
    % "escolhe" o maior "d"
[dmax,classe]=max([d0;d30;d60;d90;d120]);
    % monta a matriz de erros
if parc(nc,1)==0 & classe==1
    contin(1,1)=contin(1,1)+1;
elseif parc(nc,1)==0 & classe==2
    contin(1,2)=contin(1,2)+1;
elseif parc(nc,1)==0 & classe==3
    contin(1,3)=contin(1,3)+1;
elseif parc(nc,1)==0 & classe==4
    contin(1,4)=contin(1,4)+1;
elseif parc(nc,1)==0 & classe==5
    contin(1,5)=contin(1,5)+1;
%
elseif parc(nc,1)==30 & classe==1
    contin(2,1)=contin(2,1)+1;
elseif parc(nc,1)==30 & classe==2
    contin(2,2)=contin(2,2)+1;
elseif parc(nc,1)==30 & classe==3
    contin(2,3)=contin(2,3)+1;
elseif parc(nc,1)==30 & classe==4
    contin(2,4)=contin(2,4)+1;

```

```

elseif parc(nc,1)==30 & classe==5
    contin(2,5)=contin(2,5)+1;
%
elseif parc(nc,1)==60 & classe==1
    contin(3,1)=contin(3,1)+1;
elseif parc(nc,1)==60 & classe==2
    contin(3,2)=contin(3,2)+1;
elseif parc(nc,1)==60 & classe==3
    contin(3,3)=contin(3,3)+1;
elseif parc(nc,1)==60 & classe==4
    contin(3,4)=contin(3,4)+1;
elseif parc(nc,1)==60 & classe==5
    contin(3,5)=contin(3,5)+1;
%
elseif parc(nc,1)==90 & classe==1
    contin(4,1)=contin(4,1)+1;
elseif parc(nc,1)==90 & classe==2
    contin(4,2)=contin(4,2)+1;
elseif parc(nc,1)==90 & classe==3
    contin(4,3)=contin(4,3)+1;
elseif parc(nc,1)==90 & classe==4
    contin(4,4)=contin(4,4)+1;
elseif parc(nc,1)==90 & classe==5
    contin(4,5)=contin(4,5)+1;
%
elseif parc(nc,1)==120 & classe==1
    contin(5,1)=contin(5,1)+1;
elseif parc(nc,1)==120 & classe==2
    contin(5,2)=contin(5,2)+1;
elseif parc(nc,1)==120 & classe==3
    contin(5,3)=contin(5,3)+1;
elseif parc(nc,1)==120 & classe==4
    contin(5,4)=contin(5,4)+1;
elseif parc(nc,1)==120 & classe==5
    contin(5,5)=contin(5,5)+1;
%
end
% limpa as matrizes da validacao cruzada
clear mat_0 mat_30 mat_60 mat_90 mat_120
% *****
end % nc=1:size(mat_vez,1)
[kappa,var_kappa]=kappa_certo(contin);
% armazena kappa e var_kappa
res_kappa(tot_comb,1:size(comb_vez,2))=comb_vez;
res_kappa(tot_comb,10)=trace(contin)/sum(sum(contin));
res_kappa(tot_comb,11)=kappa;
res_kappa(tot_comb,12)=var_kappa;
res_kappa(tot_comb,13:17)=contin(1,1:5);
res_kappa(tot_comb,18:22)=contin(2,1:5);
res_kappa(tot_comb,23:27)=contin(3,1:5);
res_kappa(tot_comb,28:32)=contin(4,1:5);
res_kappa(tot_comb,33:37)=contin(5,1:5);
% *****
% passa para a proxima combinacao
clear mat_vez

end % i=1:size(comb,1)
end % n=1:indices;
toc
nome_salva=(strcat('res_duncan_estufa2_objt.txt'))
dlmwrite(nome_salva,res_kappa,'\t');

```

Apêndice H

Código-fonte do algoritmo implementado no MATLAB para elaborar e avaliar classificadores estatísticos com valores SPAD e N foliar do trigo cultivado em parcelas

```
% algoritmo para elaboracao e avaliacao de classificador estatistico
% utilizando validacao cruzada
% 3 doses de N em trigo
% valores clorofila medidos com SPAD e N foliar
%
% Darly Geraldo de Sena Jr., julho 2004.
%
clear
clc
% carrega os dados
% arquivo: resumo_medias_spad_campo
% coluna 1: parcela
% coluna 2: primeira adubacao nitrogenada (kg/ha)
% coluna 3: spad 4daa (0601)
% coluna 4: spad 8daa (0605)
% coluna 5: spad 14daa (0611)
% coluna 6: spad 20daa (0617)

% arquivo: dados_trigo_analise_n
% coluna 1: parcela
% coluna 2: primeira adubacao nitrogenada (kg/ha)
% coluna 3: N foliar 20daa (0617)
% coluna 4: spad das folhas coletadas 20 daa(0617)

[nomearq,caminho] = uigetfile('*.txt','Selecione dados de origem');
dados=dlmread(strcat(caminho,nomearq));
%
% determina o numero de medicoes
datas=size(dados,2)-2;
% monta vetor com dados de adubacao das parcelas
parc=dados(:,2);
% inicializa a matriz resultados do kappa
res_kappa=zeros(1,3);
    for i=3:datas+2
        spad=dados(:,i);
        % classificador
        % *****
        contin=zeros(3,3);
        % calcula dados para elaboracao do classificador
        % inicializa contador das classes
        % monta a matriz de cada classe para leave-one-out(loo)
        for nc=1:size(spad,1)
            conta_0=1;
            conta_30=1;
            conta_60=1;
            for c=1:size(spad,1)
                % elimina parcelas nao medidas
                if spad(c,1)>0
                    if c ~= nc
                        if parc(c,1)==0;
                            mat_0(conta_0,:)=spad(c,:);
```

```

        conta_0=conta_0+1;
    elseif parc(c,1)==30;
        mat_30(conta_30,:)=spad(c,:);
        conta_30=conta_30+1;
    elseif parc(c,1)==60;
        mat_60(conta_60,:)=spad(c,:);
        conta_60=conta_60+1;
    end
end
end
end % c=1:size(spad,1)
    % calcula media e matriz de covariancia
med_0=mean(mat_0);
    med_30=mean(mat_30);
    med_60=mean(mat_60);
    cov_0=cov(mat_0);
    cov_30=cov(mat_30);
    cov_60=cov(mat_60);
    % calcula os "d's"
d0=-0.5*(spad(nc,:)'-med_0) '*inv(cov_0)*(spad(nc,:)'-
med_0')-0.5*log(det(cov_0));
d30=-0.5*(spad(nc,:)'-med_30) '*inv(cov_30)*(spad(nc,:)'-
med_30')-0.5*log(det(cov_30));
d60=-0.5*(spad(nc,:)'-med_60) '*inv(cov_60)*(spad(nc,:)'-
med_60')-0.5*log(det(cov_60));
    % "escolhe" o maior "d"
[dmax,classe]=max([d0;d30;d60]);
% monta a matriz de erros
if parc(nc,1)==0 & classe==1
    contin(1,1)=contin(1,1)+1;
elseif parc(nc,1)==0 & classe==2
    contin(1,2)=contin(1,2)+1;
elseif parc(nc,1)==0 & classe==3
    contin(1,3)=contin(1,3)+1;
elseif parc(nc,1)==30 & classe==1
    contin(2,1)=contin(2,1)+1;
elseif parc(nc,1)==30 & classe==2
    contin(2,2)=contin(2,2)+1;
elseif parc(nc,1)==30 & classe==3
    contin(2,3)=contin(2,3)+1;
elseif parc(nc,1)==60 & classe==1
    contin(3,1)=contin(3,1)+1;
elseif parc(nc,1)==60 & classe==2
    contin(3,2)=contin(3,2)+1;
elseif parc(nc,1)==60 & classe==3
    contin(3,3)=contin(3,3)+1;
end
% limpa as matrizes da validacao cruzada
clear mat_0 mat_30 mat_60
% *****
end % nc=1:size(spad,1)
    [kappa,var_kappa]=kappa_certo(contin);
% armazena kappa e var_kappa
res_kappa(i-2,1)=i-2;
res_kappa(i-2,2)=trace(contin)/sum(sum(contin));
res_kappa(i-2,3)=kappa;
res_kappa(i-2,4)=var_kappa;
% *****
% passa para a proxima combinacao
end % i=1:size(datas)

```

Apêndice I

Código-fonte do algoritmo implementado no MATLAB para elaborar e avaliar classificadores estatísticos com valores SPAD e N foliar do trigo cultivado em vasos. Salvar a exatidão global, coeficiente kappa e matriz de contigência em arquivo texto.

```
% algoritmo para elaboracao e avaliacao de classificador estatistico
% validacao cruzada
% 5 doses de N em trigo - valores clorofila medidos com SPAD
%
% Darly Geraldo de Sena Jr., julho 2004.
%
clear
clc
% carrega os dados
% arquivo: dados_spad_estufa2_matlab.txt
% coluna 1: vaso
% coluna 2: dose
% coluna 3: spad dae15
% coluna 4: spad dae23
% coluna 5: spad dae27
% coluna 6: spad dae34
% coluna 7: spad dae41
[nomearq,caminho] = uigetfile('*.txt','Selecione dados de origem');
dados=dlmread(strcat(caminho,nomearq));
%
% determina o numero de medicoes
datas=size(dados,2)-2;
% monta vetor com dados de adubacao dos vasos
parc=dados(:,2);
% inicializa a matriz resultados do kappa
res_kappa=zeros(1,5);
    for i=3:datas+2
        disp(i)
        spad=dados(:,i);
        % ***** classificador *****
        contin=zeros(5,5);
        % calcula dados para elaboracao do classificador
        % inicializa contador das classes
        % monta a matriz de cada classe para leave-one-out(loo)
        for nc=1:size(spad,1)
            conta_0=1;
            conta_30=1;
            conta_60=1;
            conta_90=1;
            conta_120=1;
            for c=1:size(spad,1)
                % elimina parcelas nao medidas
                if spad(c,1)>0
                    if c ~= nc
                        if parc(c,1)==0;
                            mat_0(conta_0,:)=spad(c,:);
                            conta_0=conta_0+1;
                        elseif parc(c,1)==30;
                            mat_30(conta_30,:)=spad(c,:);
                            conta_30=conta_30+1;
                        elseif parc(c,1)==60;
                            mat_60(conta_60,:)=spad(c,:);
                            conta_60=conta_60+1;
```

```

elseif parc(c,1)==90;
    mat_90(conta_90,:)=spad(c,:);
    conta_90=conta_90+1;
elseif parc(c,1)==120;
    mat_120(conta_120,:)=spad(c,:);
    conta_120=conta_120+1;
end
end
end
end % c=1:size(spad,1)
    % calcula media e matriz de covariancia
med_0=mean(mat_0);
    med_30=mean(mat_30);
    med_60=mean(mat_60);
    med_90=mean(mat_90);
    med_120=mean(mat_120);
    cov_0=cov(mat_0);
    cov_30=cov(mat_30);
    cov_60=cov(mat_60);
    cov_90=cov(mat_90);
    cov_120=cov(mat_120);
    % calcula os "d's"
d0=-0.5*(spad(nc,:)-med_0) '*inv(cov_0)*(spad(nc,:)-
med_0')-0.5*log(det(cov_0));
d30=-0.5*(spad(nc,:)-med_30) '*inv(cov_30)*(spad(nc,:)-
med_30')-0.5*log(det(cov_30));
d60=-0.5*(spad(nc,:)-med_60) '*inv(cov_60)*(spad(nc,:)-
med_60')-0.5*log(det(cov_60));
d90=-0.5*(spad(nc,:)-med_90) '*inv(cov_90)*(spad(nc,:)-
med_90')-0.5*log(det(cov_90));
d120=-0.5*(spad(nc,:)-
med_120) '*inv(cov_120)*(spad(nc,:)-med_120')-0.5*log(det(cov_120));
    % "escolhe" o maior "d"
[dmax,classe]=max([d0;d30;d60;d90;d120]);
% monta a matriz de erros
% monta a matriz de erros
if parc(nc,1)==0 & classe==1
    contin(1,1)=contin(1,1)+1;
elseif parc(nc,1)==0 & classe==2
    contin(1,2)=contin(1,2)+1;
elseif parc(nc,1)==0 & classe==3
    contin(1,3)=contin(1,3)+1;
elseif parc(nc,1)==0 & classe==4
    contin(1,4)=contin(1,4)+1;
elseif parc(nc,1)==0 & classe==5
    contin(1,5)=contin(1,5)+1;
%
elseif parc(nc,1)==30 & classe==1
    contin(2,1)=contin(2,1)+1;
elseif parc(nc,1)==30 & classe==2
    contin(2,2)=contin(2,2)+1;
elseif parc(nc,1)==30 & classe==3
    contin(2,3)=contin(2,3)+1;
elseif parc(nc,1)==30 & classe==4
    contin(2,4)=contin(2,4)+1;
elseif parc(nc,1)==30 & classe==5
    contin(2,5)=contin(2,5)+1;
%
elseif parc(nc,1)==60 & classe==1
    contin(3,1)=contin(3,1)+1;
elseif parc(nc,1)==60 & classe==2

```

```

        contin(3,2)=contin(3,2)+1;
    elseif parc(nc,1)==60 & classe==3
        contin(3,3)=contin(3,3)+1;
    elseif parc(nc,1)==60 & classe==4
        contin(3,4)=contin(3,4)+1;
    elseif parc(nc,1)==60 & classe==5
        contin(3,5)=contin(3,5)+1;
    %
    elseif parc(nc,1)==90 & classe==1
        contin(4,1)=contin(4,1)+1;
    elseif parc(nc,1)==90 & classe==2
        contin(4,2)=contin(4,2)+1;
    elseif parc(nc,1)==90 & classe==3
        contin(4,3)=contin(4,3)+1;
    elseif parc(nc,1)==90 & classe==4
        contin(4,4)=contin(4,4)+1;
    elseif parc(nc,1)==90 & classe==5
        contin(4,5)=contin(4,5)+1;
    %
    elseif parc(nc,1)==120 & classe==1
        contin(5,1)=contin(5,1)+1;
    elseif parc(nc,1)==120 & classe==2
        contin(5,2)=contin(5,2)+1;
    elseif parc(nc,1)==120 & classe==3
        contin(5,3)=contin(5,3)+1;
    elseif parc(nc,1)==120 & classe==4
        contin(5,4)=contin(5,4)+1;
    elseif parc(nc,1)==120 & classe==5
        contin(5,5)=contin(5,5)+1;
    %
    end
    % limpa as matrizes da validacao cruzada
    clear mat_0 mat_30 mat_60 mat_90 mat_120
    % *****
end % nc=1:size(spad,1)
    [kappa,var_kappa]=kappa_certo(contin);
% armazena kappa e var_kappa
res_kappa(i-2,1)=i-2;
res_kappa(i-2,2)=trace(contin)/sum(sum(contin));
res_kappa(i-2,3)=kappa;
res_kappa(i-2,4)=var_kappa;
res_kappa(i-2,5:9)=contin(1,1:5);
res_kappa(i-2,10:14)=contin(2,1:5);
res_kappa(i-2,15:19)=contin(3,1:5);
res_kappa(i-2,20:24)=contin(4,1:5);
res_kappa(i-2,25:29)=contin(5,1:5);
% *****
% passa para a proxima combinacao
end % i=1:size(datas)
nome_salva=strcat('res_spad_estf2.txt');
dlmwrite(nome_salva,res_kappa,'\t');

```

Apêndice J

Código-fonte do algoritmo implementado no MATLAB para avaliar o resultado dos classificadores.

```
% avalia as combinacoes dos indices para classificacão
% Darly Geraldo de Sena Jr. - agosto 2004
%
% coluna      variavel
% 1 a 9      combinacao
% 10         exatidao global
% 11         kappa
% 12         variancia kappa

clear
clc
% carrega os dados
[nomearq,caminho] = uigetfile('*.txt','Selecione dados de origem');
dados=dlmread(strcat(caminho,nomearq));
comb=dados(:,1:9);
%
% conta as combinacoes de cada tipo
tot_comb=[1:9]';
tot_comb(:,2)=0;
comb_vis=0;
ord=sort(dados(:,11));
ord=(round(ord*100))/100;
conta_k=0;
val=0;
freq=0;
k_ant=-100;
    for i=1:size(comb,1)
        % carrega uma combinacao
        vez=nonzeros(comb(i,:));
        if i==1
            tudo=vez;
        end
        % armazena o tipo de combinacao
        tot_comb(size(vez,1),2)=tot_comb(size(vez,1),2)+1;
        % verifica se ha alguma combinacao so no visivel
        if max(vez)<=4
            comb_vis=comb_vis+1;
        end
        k=ord(i,1);
        if k~=k_ant
            conta_k=conta_k+1;
            val(conta_k,1)=k;
            freq(conta_k,1)=1;
            k_ant=k;
        else
            if size(freq,1)<conta_k
                freq(conta_k,1)=1;
            end
            freq(conta_k,1)=freq(conta_k,1)+1;
        end
    end
end
```

```

disp(strcat('combinacoes no visivel: ',num2str(comb_vis)))
disp(strcat('total combinacoes: ',num2str(sum(tot_comb(:,2)))))
tot_comb
bar(tot_comb(:,1),tot_comb(:,2))
valfreq=[val freq]
% histograma dos valores de kappa x frequencia
bar(val,freq)
xlabel('Coeficiente kappa')
ylabel('Frequência')
title('14 DAA - Reflectância')
% histograma das combinacoes x frequencia
figure;
bar(tot_comb(:,1),tot_comb(:,2))
xlabel('N° de índices combinados')
ylabel('Frequência')
title('14 DAA - Reflectância')

```

Apêndice K

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

```
% algoritmo para calcular indice kappa
% setembro 2003
% Darly Geraldo de Sena Jr. - Joseph Kalil Khoury Jr.

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);
tetal=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=tetal*(1-tetal)/(1-teta2)^2;
parc2=2*(1-tetal)*(2*tetal*teta2-teta3)/(1-teta2)^3;
parc3=(1-tetal)^2*(teta4-4*teta2^2)/(1-teta2)^4;
var_k=(parc1+parc2+parc3)/n;
```

Apêndice L

Código-fonte do algoritmo implementado no MATLAB para limiarização automática

```
% DEA - UFV outubro 2002
% função para binarização de imagens utilizando
% o método iterativo de limiarização.
%
% Darly Geraldo de Sena jr.
%
function bin= limiterativo(ima)
% acha os valores dos pixels
[np, vp]=imhist(ima);
% busca o primeiro valor válido
cont=1;
while np(cont)==0
    cont=cont+1;
end
% cria valores iniciais para limiar e mi
t=(max(vp));
mi=vp(cont);
while mi<=t & mi<=max(vp)
    sc1=0;
    sc2=0;
    npc1=0;
    npc2=0;
    for j=0:mi % acha media da classe 1
        sc1=sc1+vp(j+1)*np(j+1);
        npc1=npc1+np(j+1);
    end
    for k=mi+1:max(vp) % acha media da classe 2
        sc2=sc2+vp(k+1)*np(k+1);
        npc2=npc2+np(k+1);
    end
    t=round((sc1/npc1+sc2/npc2)/2); % acha valor limiar
    mi=mi+1; % passa para o próximo valor de pixel
end
% cria a imagem binária
bin=im2bw(ima,t/255);
```