

**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Dados hiperespectrais para predição do teor foliar de nitrogênio em cana-
de-açúcar**

Juliano Araujo Martins

Tese apresentada para obtenção do título de Doutor em
Ciências. Área de concentração: Engenharia de Sistemas
Agrícolas

**Piracicaba
2016**

Juliano Araujo Martins
Engenheiro Agrônomo

Dados hiperespectrais para predição do teor foliar de nitrogênio em cana-de-açúcar
versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **PETERSON RICARDO FIORIO**

Tese apresentada para obtenção do título de Doutor em
Ciências. Área de concentração: Engenharia de Sistemas
Agrícolas

Piracicaba
2016

**Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA - DIBD/ESALQ/USP**

Martins, Juliano Araujo

Dados hiperspectrais para predição do teor foliar de nitrogênio em cana-de-açúcar /
Juliano Araujo Martins. - - versão revisada de acordo com a resolução CoPGr 6018 de
2011. - - Piracicaba, 2016.

65 p. : il.

Tese (Doutorado) - - Escola Superior de Agricultura "Luiz de Queiroz".

1. Sensores 2. Adubação nitrogenada 3. Seleção de variáveis 4. Índices de Vegetação
5. Modelos de regressão I. Título

CDD 633.61
M386d

"Permitida a cópia total ou parcial deste documento, desde que citada a fonte – O autor"

AGRADECIMENTOS

À **Universidade de São Paulo, Escola Superior de Agricultura “Luiz de Queiroz”**, que por meio do programa de pós-graduação em Engenharia de Sistemas Agrícolas, possibilitou a realização do meu curso de doutorado.

Gostaria de expressar minha gratidão a meu orientador **Peterson Ricardo Fiorio**, pelo seu suporte, orientação, amizade e também por me apresentar esta linha de pesquisa.

À **Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP)**, por fomentar o projeto de pesquisa nº 2013/22435-9 ao qual este trabalho se insere.

À **Financiadora de Estudos e Projetos (FINEP)**, que por meio do projeto PROSENSAP, possibilitou a aquisição do radiômetro e da esfera integradora utilizados neste trabalho.

Ao Pesquisador **Heitor Cantarella** e sua equipe de pesquisa do **Instituto Agrônomo de Campinas**, que por meio de parcerias possibilitou o desenvolvimento deste trabalho junto a áreas experimentais referente projeto temático BIOEN/FAPESP 2008/56147-1.

Gostaria de agradecer também as amigadas que cultivei nos anos em que estive na instituição, em especial **Pedro Paulo da Silva Barros, Magda Maria Zuleta Bonilla, Érica Silva Nakai, Isaac de Matos Ponciano e Rodrigo Muniz**.

A todos os Professores com quem tive contato nestes anos, podendo desfrutar de ótimas aulas e conversas informais que propiciaram sem dúvida, grande evolução na minha longa jornada em busca do conhecimento.

Aos demais colegas de departamento, que direta ou indiretamente contribuíram com a realização deste trabalho.

Aos funcionários do departamento de Engenharia de Biosistemas, pela cordialidade e suporte sempre que necessitei.

Por último, mas não menos importante, gostaria de agradecer a minha família, em especial meus pais **Cícero Araujo Martins** e **Pedrina Leones da Silva Martins** e minha esposa **Kelsiane Cardoso Oliveira**, que além de serem a razão principal de meu caminhar, são minha fonte de inspiração, alegria e alento sempre que preciso.

EPÍGRAFE

“É no buscar e não no achar que nasce o que eu não conhecia”.

Clarice Lispector

SUMÁRIO

RESUMO	9
ABSTRACT	11
1 INTRODUÇÃO.....	13
2 REVISÃO BIBLIOGRÁFICA.....	15
2.1 A cultura da cana-de-açúcar e adubação nitrogenada	15
2.2 Sensoriamento remoto aplicado ao estudo da vegetação	16
2.3 Utilização de sensores remotos no monitoramento do nitrogênio em culturas	19
3. MATERIAL E MÉTODOS.....	21
3.2.1 Descrição do experimento	21
3.2.2 Coleta e armazenamento de amostras.....	22
3.2.3 Análises espectrais e do teor de nitrogênio foliar.....	23
3.2.4 Análise univariada dos dados	24
3.2.5 Análise de componentes principais	24
3.2.6 Análise de regressão simples utilizando índices de vegetação citados em literatura	24
4. RESULTADOS E DISCUSSÃO	29
4.1 Resultados para a análise foliar de nitrogênio e balanço hídrico para as áreas experimentais na safra 2012/13 e 2013/14	29
4.2 Análise de bandas individuais utilizando os resultados de todas as variedades e áreas experimentais combinadas.....	33
4.3 Análise de componentes principais para os dados das três áreas experimentais incorporando todas as doses e variedades.....	37
4.4 Performance dos índices de vegetação, levantados em literatura para predição do teor foliar de nitrogênio.....	42
4.5 Seleção de variáveis preditoras pelo método sPLS	47
4.6 Calibração de modelos de regressão linear múltipla por “ <i>stepwise</i> ” (SMLR) para predição do teor foliar de nitrogênio em cana-de-açúcar	48
5 CONCLUSÕES	53
REFERÊNCIAS	55
ANEXOS	63

RESUMO

Dados hiperespectrais para predição do teor foliar de nitrogênio em cana-de-açúcar

Uma das alternativas bastante abordada na literatura para a melhoria do gerenciamento da adubação nitrogenada nas culturas é o sensoriamento remoto, tendo destaque a utilização de sensores espectrais na região do visível e infravermelho. Neste trabalho, buscou-se estabelecer as relações existentes entre variações no teor foliar de nitrogênio (TFN) e a resposta espectral da folha de cana-de-açúcar, utilizando um sensor hiperespectral, com avaliações em três áreas experimentais do estado de São Paulo, com diferentes solos e variedades. Cada experimento foi alocado em blocos ao acaso, com parcelas subdivididas e quatro repetições. Foram aplicadas doses de 0, 50, 100 e 150 kg de nitrogênio por hectare. A análise espectral foi realizada na folha "+1" em laboratório, sendo coletadas 10 folhas por subparcela, estas foram posteriormente submetidas a análise química para o TFN. Observou-se que existe correlação significativa entre o TFN e as variações na resposta espectral da cana-de-açúcar, sendo que a região do verde e de transição entre o vermelho e o infravermelho próximo ("*red-edge*") foram as mais consistentes e estáveis entre as áreas em estudo e safras avaliadas. A análise de componentes principais permitiu reforçar estes resultados, uma vez que as pontuações ("*scores*") dos componentes que apresentaram correlações significativas com o TFN, tiveram maiores pesos ("*loadings*") nas regiões espectrais citadas anteriormente. A partir das curvas espectrais foram também realizados os cálculos dos índices de vegetação já descritos em literatura, e estes submetidos a análise de regressão simples para predição do TFN, sendo os modelos calibrados com dados da safra 2012/13 e validados com os dados da safra 2013/14. Índices espectrais calculados com a combinação dos comprimentos de onda do verde e/ou "*red-edge*" com comprimentos de onda do infravermelho próximo tiveram bom desempenho na fase de validação, sendo que os cinco mais estáveis foram os índices BNi (500, 705 e 750 nm), GNDVI (550 e 780 nm), NDRE (790 e 720 nm), RI-1db (735 e 720 nm) e VOGa (740 e 720 nm). A variedade SP 81 3250 foi cultivada nas três áreas experimentais, o que permitiu a comparação do potencial de modelos calibrados por área, com um modelo generalista para uma mesma variedade cultivada em diferentes condições edáficas. Observou-se que embora o modelo generalista apresente parâmetros estatísticos significativos, existe redução expressiva da sensibilidade de predição quando comparado aos modelos calibrados por área experimental. Empregou-se também nesta pesquisa a análise de regressão linear múltipla por "*stepwise*" (RLMS) que gerou modelos com boa precisão na estimativa do TFN, mesmo quando calibrados por área experimental, independentes da variedade, utilizando de 5 a 6 comprimentos de onda. Concluímos com a presente pesquisa que comprimentos de onda específicos estão associados a variação do TFN em cana-de-açúcar, e estes são reportados na região do verde (próximos a 550 nm) e na região de transição entre os comprimentos de onda do vermelho e infravermelho próximo (680 a 720 nm). Apesar da baixa correlação entre a região do infravermelho próximo com o TFN, índices de vegetação calculados a partir destes comprimentos de onda ou a inserção destes na geração de modelos lineares foram importantes para melhorar a precisão da predição.

Palavras-chave: Sensores; Adubação nitrogenada; Seleção de variáveis; Índices de vegetação; Modelos de regressão

ABSTRACT

Hyperspectral data to predict sugarcane leaf nitrogen content

An alternative method, quite cited in literature to improve nitrogen fertilization management on crops is the remote sensing, highlighted with the use of spectral sensors in the visible and infrared region. In this work, we sought to establish the relationship between variations in leaf nitrogen content and the spectral response of sugarcane leaf using a hyperspectral sensor, with assessments in three experimental areas of São Paulo state, Brazil, with evaluations in different soils and varieties. Each experimental area was allocated in randomized block, with splitted plots and four repetition, hence, receiving doses of 0, 50, 100 and 150 kg of nitrogen per hectare. Spectral analysis was performed on the "+1" leaf in laboratory; we collected 10 leaves per subplots; which were subsequently subjected to chemical analysis to leaf nitrogen content determination. We observed a significant correlation between leaf nitrogen content and variations in sugarcane spectral response, we noticed that the region of the green light and red-edge were the most consistent and stable among the studied area and the crop seasons evaluated. The principal component analysis allowed to reinforce these results, since that the scores for principal components showed significant correlations with the leaf nitrogen content, had higher loadings values for the previous spectral regions mentioned. From the spectral curves were also performed calculations of spectral indices previously described in literature, being these submitted to simple regression analysis to direct prediction of leaf nitrogen content. The models were calibrated with 2012/13 and validated with 2013/14 crop season data. Spectral indices that were calculated with green and/or red-edge, combined with near-infrared wavelengths performed well in the validation phase, and the five most stable were the BNi (500, 705 and 750 nm), GNDVI (550 and 780 nm), NDRE (790 and 720 nm), IR-1dB (735 and 720 nm) and VOGa (740 and 720 nm). The variety SP 81 3250 was cultured in the three experimental areas, allowing to compare the performance of a specific site model with a general model for the same variety growing on different soil conditions. Although the general model presents meaningful statistical parameters, there is a significant reduction in sensitivity to predict leaf nitrogen content of sugarcane when compared with specific site calibrated models. We also used on this research the stepwise multiple linear regression (SMLR) that generated models with good precision to estimate the leaf nitrogen content, even when models are calibrated for an experimental area, regardless of spectral differences between varieties, using 5 to 6 wavelengths. This study shows that specific wavelengths are associated with variation in leaf nitrogen content of sugarcane, and these are reported in the region of green (near to 550 nm) and red-edge (680 to 720nm). Despite the low correlation observed between the infrared wavelengths to the leaf nitrogen content of sugarcane, vegetation indices calculated from these wavelengths, or its insertion on linear models generation were important to improve prediction accuracy.

Keywords: Sensors; Nitrogen fertilization; Variable selection; Vegetation index; Regression models

1 INTRODUÇÃO

A aplicação de fertilizantes nitrogenados no decorrer do desenvolvimento das culturas, é uma técnica que demonstra notória melhoria em relação ao aproveitamento do nitrogênio (N) pela planta, com significativa redução de custos e riscos de passivos ambientais, sendo tal atividade vista como amplamente positiva à melhoria da eficiência dos sistemas de produção agrícola.

Franco et al. (2011), mostraram em sua pesquisa que no desenvolvimento inicial da cana-de-açúcar, 40 a 70% do nitrogênio consumido pela cana planta e soqueira respectivamente provém da aplicação de fertilizantes, no entanto devido ao aumento da contribuição de outras fontes durante o ciclo da cultura estes valores descessem, chegando a patamares de 5 a 10% para cana planta e de 10 a 35% para soqueira.

A cultura da cana-de-açúcar é altamente responsiva a adubação nitrogenada, e se tratando de uma cultura semi-perene, a má, ou mesmo não administração deste nutriente, nem sempre reflete em perdas de produtividade na safra corrente, mas os efeitos são perceptíveis a longo prazo, podendo resultar, além das perdas de produção, na redução da longevidade dos canaviais (VITTI et al., 2007). O excesso deste nutriente também traz efeitos negativos do ponto de vista fitotécnico, reduzindo a concentração de sacarose e atrasando a maturação (THORBURN; MEIER; PROBERT, 2003),

Apesar da existência de métodos para o monitoramento do nitrogênio nas culturas, tais quais: método do clorofilômetro, análises de solos e tecidos vegetais; estes se tornam impraticáveis para o monitoramento de grandes áreas. O primeiro, principalmente devido à baixa agilidade do processo, já o segundo e o terceiro, além de demandarem tempo para aquisição do resultado, são invasivos e caros, uma vez que grande número de amostragens se tornam necessárias para representar a variabilidade espacial (RANJAN et al., 2012).

A espectrorradiometria, tem sido amplamente citada como uma grande aliada a melhoria da eficiência dos sistemas produtivos agrícolas, como ferramenta ágil, eficaz e de baixo custo no monitoramento das culturas, e estudos sobre o uso destes sensores no monitoramento do nitrogênio (N), tem tomado grande destaque nas últimas duas ou três décadas (CAMMARANO et al., 2014; PRADHAN et al., 2014; QUEMADA; GABRIEL; ZARCO-TEJADA, 2014).

Vários estudos têm utilizado o sensoriamento remoto na avaliação de campos produtivos, por meio de sensores ativos e passivos, à nível terrestre (VIGNEAU et al., 2011; MAHAJAN et al., 2014), aéreo (LEBOURGEOIS et al., 2012) e orbital (HERRMANN et al.,

2011), sendo que alguns trabalhos têm sido desenvolvidos em campos produtivos de cana-de-açúcar no Brasil, com destaque ao administração de adubação de nitrogenada (AMARAL et al., 2014; AMARAL; MOLIN; SCHEPERS, 2015; ROSA et al., 2015).

No entanto, estas pesquisas conduzidas nas condições de produção brasileiras têm basicamente adotado as tecnologias de sensores ativos, previamente desenvolvidas para outras culturas agrícolas e regiões do globo. Sensores ativos que trabalham em comprimentos de onda e índices de vegetação padrão, podem não apresentar os melhores resultados quando diretamente utilizados em campos de cana-de-açúcar, devido principalmente as características fisiológicas particulares da cultura e também as condições edafoclimáticas locais.

Qual seria então a real capacidade da utilização de dados hiperespectrais para geração de modelos para o monitoramento de variações no estado nutricional de nitrogênio em cana-de-açúcar? Visando responder esta pergunta, a presente pesquisa teve como objetivo selecionar os comprimentos de onda com maior correlação com a variação do teor foliar de nitrogênio em cana-de-açúcar quando cultivada sobre diferentes níveis de adubação nitrogenada, bem como definir modelos de regressão com os dados de reflectância da cultura para estimativa do estado nutricional de nitrogênio.

2 REVISÃO BIBLIOGRÁFICA

2.1 A cultura da cana-de-açúcar e adubação nitrogenada

O Brasil é o principal produtor mundial de cana-de-açúcar, onde se pode também destacar a participação da Índia e China (FNP, 2008). Os maiores estados produtores de cana no país para safra 2014/15 foram: São Paulo, Goiás, Minas Gerais, Paraná, Mato Grosso do Sul, Alagoas, Mato Grosso e Pernambuco, onde estes 8 estados representaram mais de 95% da produção nacional em uma safra que atingiu patamares de 632 milhões de toneladas (UNIÃO DA INDÚSTRIA DE CANA-DE-AÇÚCAR - UNICA, 2016)

A planta de cana-de-açúcar pertencente à família Poaceae e ao gênero *Saccharum*, que possui várias espécies. No entanto, as variedades comercialmente cultivadas hoje são híbridas (FIGUEIREDO, 2008). Embora seu centro de origem seja incerto, é provável que a cana seja nativa do sudeste da Ásia, tendo sido levada para outros continentes. Porém, a cana-de-açúcar encontrou as melhores condições para seu desenvolvimento no continente americano, onde atualmente localizam-se as maiores plantações do mundo. Apresenta boa adaptação em áreas de clima tropical, com temperaturas entre 19° e 32° C, chuvas bem distribuídas, e precipitação acumulada superior a 1000 mm ano⁻¹ (FIGUEIREDO, 2008).

A cana-de-açúcar possui desenvolvimento em forma de touceira e apresenta perfilhamento. A parte aérea é formada por colmos, folhas, inflorescências e frutos, e a subterrânea, por raízes e rizomas. O colmo tem como característica a presença de nós bem formados e entrenós, e é responsável pela sustentação de folhas e da panícula. A folha completa da cana-de-açúcar é composta por lâmina foliar, bainha e colar, estando ligada ao colmo na região nodal. As raízes são fasciculadas e 85% delas se encontram nos primeiros 50 cm de solo. Os rizomas são constituídos de gemas, que são responsáveis pela formação dos perfilhos na touceira, e que rebrotarão após a colheita (SEGATO et al., 2006).

A adubação nitrogenada é uma das operações de maior interesse em relação à produtividade das culturas, uma vez que o nitrogênio é um elemento requerido em altas quantidades e sua dinâmica no sistema solo-planta-atmosfera é muito complexa (FRANCO et al., 2010). No atual sistema produtivo da cana-de-açúcar, onde não ocorre mais a queima da palha, têm ocorrido aumento substancial nas doses de nitrogênio recomendadas em cobertura para os ciclos de sequeira, sendo que, segundo Cantarella et al. (2007), o percentual do N recuperado pela cultura em relação ao aplicado em boas condições de manejo, consegue alcançar valores de 40%.

Devido à alta complexidade deste nutriente no ambiente, sua importância no rendimento das culturas e sua expressiva participação nos custos de produção, alguns cuidados devem ser atentados em sua administração, sendo os três principais: sincronizar as aplicações com os períodos de demanda da cultura, considerar os diferentes potenciais de resposta ao nitrogênio e atender a variabilidade espacial da necessidade do nutriente (SOLARI et al., 2008).

Otto et al. (2014) observaram em seu estudo que a aplicação de nitrogênio sobre a palhada tem efeito no aumento na produtividade e densidade das raízes, porém os resultados foram variáveis entre áreas as experimentais avaliadas. Franco et al. (2015) em trabalho de campo para onze diferentes áreas relatam que apenas de 30 a 40% do nitrogênio aplicado no plantio é aproveitado pela cultura, sendo que destes 75% ocorrem ainda no ciclo de cana planta e apenas 13, 7 e 5% na primeira, segunda e terceira soqueira respectivamente. O baixo efeito residual deste nutriente torna necessário o uso de grandes doses de nitrogênio nos ciclos de soqueira da cana-de-açúcar e este fato tem consequências negativas sobre a viabilidade econômica e meio ambiente (FRANCO et al., 2015).

Existem grandes variações na literatura em relação à melhor dose a ser aplicada na cana-de-açúcar, sendo que estas diferenças estão diretamente ligadas à variedade, tipo de solo, região de estudo e sistema de cultivo (KORNDÖRFER; PEREIRA; CAMARGO, 2002; BOLOGNA-CAMPBELL, 2007; FRANCO et al., 2010). Desta maneira a possibilidade do desenvolvimento de ferramentas capazes de determinar em diferentes condições de cultivo de maneira ágil e não invasiva, o estado nutricional da cana-de-açúcar, viabilizaria ações para minimização de custos, com ganhos em rendimento e menor risco de passivos ambientais.

2.2 Sensoriamento remoto aplicado ao estudo da vegetação

O rápido avanço tecnológico das últimas décadas impulsionou também o desenvolvimento de diferentes sistemas de sensores remotos, que são atualmente utilizados nas mais diversas áreas da ciência (JENSEN, 2009). Desde a década de 1960, cientistas vêm extraindo e modelando muitos parâmetros biofísicos da vegetação com o uso do sensoriamento remoto; grande parte desse esforço envolve a utilização de índices de vegetação, os quais se configuram como medidas radiométricas adimensionais, que indicam a abundância relativa e a atividade da vegetação verde, incluindo índice de área foliar, porcentagem de cobertura verde, teor de clorofila, biomassa verde, radiação fotossinteticamente ativa absorvida, entre outros (JENSEN, 2009).

A aplicação do sensoriamento remoto na agricultura é baseada na interação da radiação eletromagnética com o alvo, que pode ser o solo ou a planta (MULLA, 2013). A interpretação desta interação, gera dados que podem servir de parâmetro para a tomada de decisão. Portanto é de fundamental importância que se tenha o conhecimento de quais fatores presentes no alvo que podem alterar o comportamento da radiação refletida por ele. O estudo dessas interações pode ser feito através da radiometria, que de acordo com Steffen et al. (1996), pode ser definida como um conjunto de técnicas utilizadas para medir quantitativamente a energia radiante, e os sistemas utilizados para a medição desta energia são os radiômetros.

A radiometria permite a identificação da intensidade que cada material reflete a energia em diferentes comprimentos de onda através de medidas radiométricas de campo e laboratório, ajudando a explicar e a entender a forma como esses objetos serão mostrados em imagens aéreas e orbitais, bem como definir padrões de comportamento para a ocorrência de fenômenos específicos (SILVA; GRIEBELER; BORGES, 2007).

Para entender a interação da radiação eletromagnética com a vegetação, a primeira coisa que se deve fazer segundo Moreira (2011), é conhecer a estrutura e funções das folhas, pois são basicamente nelas que se processam todas as reações fotoquímicas como a fotossíntese, respiração e a transpiração.

Já são conhecidos alguns fatores que alteram certas regiões do espectro eletromagnético. A região do visível, que compreende os comprimentos de onda de 400 a 760 nm, é influenciada pela quantidade de pigmentos nas folhas, que são as clorofilas “a” e “b”, os carotenos, e as xantofilas (PONZONI; SHIMABUKURO; KUPLICH, 2012). Essas características podem variar entre diferentes variedades, o que pode implicar em uma mudança na resposta espectral. A radiação interage com a folha por absorção e espalhamento, a energia é absorvida seletivamente pela clorofila, sendo convertida em calor ou em fluorescência (PONZONI; SHIMABUKURO; KUPLICH, 2012).

O infravermelho próximo abrange a região de comprimento de onda de 760 a 1300 nm. Nesta região ocorre menor absorção de radiação e maior espalhamento interno na folha, sendo sua reflectância quase constante. A reflectância é alterada de acordo com a estrutura do mesófilo, como o tamanho das células e o espaço entre elas, o número de camadas celulares e a relação entre água e ar nos espaços intercelulares, geralmente quanto mais lacunosa for a estrutura foliar, maior será a taxa de reflectância (PONZONI; SHIMABUKURO; KUPLICH, 2012).

A região do infravermelho médio, que abrange os comprimentos de onda de 1300 nm a 3200 nm, apresenta maior absorbância em virtude da maior quantidade de água no interior da folha e pode se alterar de acordo com a quantidade de água disponível para a planta (MOREIRA, 2012). Folhas saudáveis apresentam comportamento espectral semelhante, porém, fatores como idade, doenças, deficiência de água e nutrientes podem alterar suas propriedades espectrais.

As mudanças causadas na atividade fotossintética, estrutura celular, alongamento e componentes bioquímicos das plantas são partes do princípio envolvido no uso do sensoriamento remoto para determinar o estresse nutricional das culturas agrícolas (CURRAN, 1989), pois alteram a reflectância espectral das plantas nas regiões do visível (VIS), infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR).

Segundo Dorigo et al. (2007), o espectro da reflectância de dossel pode refletir o estado fisiológico de uma população de plantas, cuja informação da mistura espectral é influenciada pelas propriedades da folha, estrutura do dossel, solo e condições atmosféricas. Deste modo, a minimização das interferências do solo e exploração dos dados de reflectância do dossel em função do nitrogênio são de grande importância para um potencial monitoramento do crescimento da cultura.

Os Índices de Vegetação podem minimizar efetivamente os efeitos de várias interferências externas e aumentar a sensibilidade da reflectância ao nitrogênio da planta (ZHAO et al., 2007). O primeiro índice de vegetação verdadeiro proposto foi o de razão simples, que é a razão entre o fluxo radiante refletido no infravermelho próximo e o fluxo radiante refletido no vermelho (BIRTH; MCVEY, 1968). Desde então muitos índices de vegetação surgiram, todos partindo deste mesmo princípio; dentre eles os mais conhecidos são: o índice de vegetação por diferença normalizada (NDVI), índice de vegetação ajustado por solo (SAVI), índice de vegetação da região espectral do verde (GVI), índice de vegetação reverso (RVI), entre outros (RAMIREZ; ZULLO JUNIOR, 2010).

Estes índices ainda são altamente úteis para diversos fins até os tempos atuais. No entanto, com o desenvolvimento de sensores com maior resolução espectral, muitos estudos estão se direcionando à determinação de bandas ou índices espectrais específicos para o estudo de diferentes ambientes ou culturas de interesse. O comportamento espectral das culturas agrícolas varia ao longo de seu ciclo, sendo que a modelagem de um parâmetro específico pode ter melhor resultado durante uma fase específica da cultura, o que nem sempre condiz com a fase de interesse técnico para mensuração da mesma (LI et al., 2010).

O potencial do sensoriamento remoto no estudo da vegetação já é do consenso científico, e deve ser uma das ferramentas mais úteis nas atividades agrícolas em um futuro próximo, haja visto o aumento do número de sensores embarcados em plataformas aéreas e orbitais, com melhorias na resolução espectral, e estes vem sendo direcionados por estudos de campo e laboratório. Porém, o desenvolvimento e aprimoramento de modelos que transformem os dados da energia refletida pelas culturas em informações interpretáveis e aplicáveis no sistema produtivo é uma área de estudo que possui ainda muito espaço para ampliação de conhecimento.

2.3 Utilização de sensores remotos no monitoramento do nitrogênio em culturas

No atual estado da arte observa-se que os sensores ópticos têm ganhado destaque na literatura como método inovador que envolve praticidade, agilidade e eficiente para avaliar do estado nutricional de N em culturas (RANJAN et al., 2012). Vários estudos de base, com sensores hiperespectrais apoiaram o desenvolvimento de sensores dedicados à avaliação de parâmetros dos campos de produção, sobretudo o nitrogênio foliar (SHAVER; KHOSLA; WESTFALL, 2011).

O nitrogênio acumulado na folha pode fornecer informações completas sobre a concentração de nitrogênio foliar na planta auxiliando na detecção de deficiências, que podem comprometer a produtividade. Portanto sua estimativa pode efetivamente dar suporte ao uso correto de fertilizantes nas culturas (WANG; LI, 2012).

Algumas tentativas de validação e uso de sensores espectrais foram realizadas no Brasil, em trigo, triticale, cevada, milho e cana-de-açúcar (MOLIN, 2010; AMARAL et al., 2014; ROSA et al., 2015). No entanto estes sensores possuem limitações em relação aos comprimentos de onda em que trabalham, pois não permitem alterações dos mesmos. Dessa forma, seu uso em diferentes culturas pressupõe que estas faixas do espectro representem bem o estado nutricional dos diferentes cultivos.

Os resultados do trabalho de Li et al. (2010), mostram que para a cultura do trigo o desenvolvimento de um novo índice dedicado ao monitoramento do nitrogênio foliar demonstrou melhores resultados se comparado com diferentes índices de vegetação já propostos na literatura, sendo o mesmo fato constatado por Ryu, Suguri e Umeda (2009) estudando a cultura arroz.

Nigon et al. (2015) avaliaram a capacidade do sensoriamento remoto hiperespectral no monitoramento do estresse por N em batatas e concluíram, com base em índices espectrais, que a aplicação do índice de vegetação MERIS Terrestrial Chlorophyll Index (MTCI) foi a

técnica mais promissora para a determinação do estresse por N na cultura, devido a uma combinação de valores relativamente elevados de R^2 e RMSE baixos que sugerem a confiabilidade deste índice.

Cammarano et al. (2014) verificaram uma boa correlação entre os teores de nitrogênio da cultura do trigo, cultivada na região do mediterrâneo, com índices espectrais gerados a partir de comprimentos de onda da região do “*red-edge*”, descrito na literatura como zona de inflexão na reflectância da vegetação, situada entre a borda limite aos comprimentos de onda do vermelho e infravermelho próximo.

Ferwerda e Skidmore (2007) demonstraram o potencial do sensoriamento remoto hiperespectral na previsão da concentração de nutrientes essenciais, tais como N, P, Ca, K, Na e Mg em culturas perenes. Eles também observaram uma mudança de posição da região do “*red-edge*” para comprimentos de onda mais curtos, para deficiência dos diferentes elementos nutricionais estudados.

Mahajan et al. (2014) analisaram a relação quantitativa entre a reflectância hiperespectral de folha e dossel e o estado nutricional envolvendo taxas de aplicação de nutrientes variáveis ao longo de dois anos consecutivos, cujos resultados do experimento demonstraram que as medições radiométricas podem ser utilizadas no monitoramento de N, P, S e K na cultura de trigo.

Grande número de estudos vem sendo desenvolvidos com o objetivo de se determinar modelos específicos para o monitoramento de N a partir de dados hiperespectrais em diversos cultivos agrícolas, como milho (ERDLE; MISTELE; SCHMIDHALTER, 2011), trigo (LI et al., 2010; VIGNEAU et al., 2011), arroz (STROPPIANA et al., 2009; TIAN et al., 2011b; YI et al., 2012), feijão (REDDY; MATCHA, 2010), pastagem (BIEWER; FRICKE; WACHENDORF, 2009; SKIDMORE et al., 2010; KNOX et al., 2011), entre outros.

No entanto, para cana-de-açúcar estes estudos ainda foram pouco explorados, existindo algumas pesquisas sobre o comportamento espectral da folha (ABDEL-RAHMAN et al., 2010; BEGUE et al., 2010), sendo ainda mais raras investigações utilizando sensores hiperespectrais (MIPHOKASAP et al., 2012). Porém, estes poucos trabalhos, têm mostrado resultados promissores, gerando modelos com boa exatidão no diagnóstico da condição nutricional da cultura em relação ao nitrogênio.

3. MATERIAL E MÉTODOS

3.2.1 Descrição do experimento

O presente trabalho foi conduzido em áreas experimentais em três localizações do estado de São Paulo (Tabela 1). De acordo com a classificação climática de Köppen, a região possui clima subtropical úmido (Cwa), com média pluviométrica inferior a 1400 mm, sendo o verão úmido e o inverno seco.

Tabela 1 - Localização e descrição das áreas experimentais

	Área 1	Área 2	Área 3
Localização	Jaú	Piracicaba	Santa Maria da Serra
Descrição	Polo Centro-Oeste (APTA)	Polo Centro-Sul (APTA)	Fazenda Itaúna - Raizen
Coordenadas	22°15'08"S; 48°34'04"O	22°41'05"S; 47°38'54"O	22°33'26"S; 48°16'42"O
Classificação do solo	Latossolo Vermelho (LV)	Podzólico Vermelho-Amarelo (PVA)	Neossolo Quartzarênico (RQ)
Textura do solo	Franco Arenosa (0-20 cm), Franco argiloarenosa (20-40 cm)	Argilosa (0-20 cm) Muito Argilosa (20-40 cm)	Arenosa (0-40 cm)

Todas as áreas experimentais foram instaladas em 2010, utilizando o delineamento em blocos ao acaso, com parcelas subdivididas, onde as parcelas eram diferenciadas pelas variedades e as subparcelas por quatro doses de nitrogênio (Tabela 2). As áreas receberam as variações nas doses de nitrogênio desde o primeiro ciclo, no entanto, as avaliações foram realizadas nas safras 2012/13 e 2013/14, ou seja, durante o terceiro e quarto ciclo produtivo (Tabela 2).

Tabela 2 - Variedades cultivadas e doses de nitrogênio aplicadas

Localização	Variedade	Doses de N (kg ha ⁻¹)
Área 1	SP 81-3250 IAC 95-5000 RB 85-5536	0, 50, 100 e 150
Área 2	SP 81-3250 IAC 87-3396 CTC 14	0, 50, 100 e 150
Área 3	SP 81-3250 RB 96579 RB 86-7515	0, 50, 100 e 150

Observa-se que a variedade SP 81-3250 é comum nas três áreas experimentais. Tal fato teve como objetivo possibilitar a comparação do efeito do ambiente sobre o mesmo material genético. Todas as demais variedades foram selecionadas de acordo com a capacidade de adaptação para diferentes condições de fertilidade de solo. Cada subparcela era composta de cinco fileiras de cana-de-açúcar, espaçadas em 1,5 m, com 10 m de comprimento, onde foi considerada como área de avaliação, as três fileiras centrais, descartando 1 m das extremidades, afim de evitar os efeitos de bordadura.

As correções iniciais e anuais do solo foram realizadas de acordo com as recomendações para a cultura, diagnosticadas e recomendadas com base em análises de rotina para fertilidade de solo. As doses de nitrogênio foram aplicadas utilizando o nitrato de amônio, distribuído sobre a palhada da cana-de-açúcar em dose única, no início de cada ciclo. Todos os demais tratamentos fitossanitários seguiram os padrões do sistema produtivo regional adotados pelos produtores de cana-de-açúcar.

3.2.2 Coleta e armazenamento de amostras

Para as análises espectrais e do teor foliar de nitrogênio, foram coletadas dez folhas por subparcela quando a cultura se encontrava próxima a fase de máximo desenvolvimento vegetativo que para a cana-de-açúcar coincide aproximadamente a quatro meses após a brotação da soqueira. As folhas coletadas são descritas na literatura como folha “+1”, sendo esta, a primeira folha com o ponto de separação entra a lâmina foliar e a bainha, visível, de acordo com o sistema Kuijper's (CASAGRANDE, 1991).

Após coletadas, as folhas foram imediatamente armazenadas em sacolas plásticas e aclimatadas em caixas térmicas com gelo sem haver contato direto (afim de reduzir ao máximo as perdas de umidade) e enviadas imediatamente ao laboratório para análise espectral das folhas frescas, o que ocorria entre duas e quatro horas após a coleta. Todas as etapas de coleta descritas acima estão ilustradas na Figura 1.



Figura 1 – Sistemática da coleta das amostras foliares de cana-de-açúcar para análise espectral e do teor foliar de nitrogênio. A. Folha diagnóstico (+1); B. Folha coletada e com o terço médio destacado; C. Amostragem de uma parcela coletada e identificada em sacola plástica; D. Armazenamento das amostras em caixa térmica com gelo.

3.2.3 Análises espectrais e do teor de nitrogênio foliar

As curvas espectrais das folhas de cana-de-açúcar foram obtidas utilizando o sensor hiperespectral FieldSpec 3 Spectrorradiometer (ASD – Analytical Spectral Devices Inc., Boulder, CO, USA), que opera na região espectral de 350 a 2500 nm, com resolução espectral de 1.4 nm entre 350 e 1050 nm e 2 nm de 1050 a 2500 nm, acoplado a uma esfera integradora, modelo RTS-3ZC (ASD – Analytical Spectral Devices Inc., Boulder, CO, USA), configurada para realização de leituras de reflectância da folha. No momento da coleta os dados espectrais foram automaticamente interpolados para a resolução de 1 nm.

As leituras espectrais foram realizadas no terço médio das folhas coletadas. Após as leituras, foram calculadas as curvas espectrais médias por subparcela, utilizando as 10 folhas coletadas, sendo previamente eliminadas curvas espectrais das amostras cujo valor de reflectância fosse maior que duas vezes o desvio padrão em relação à média da parcela. Estas amostras foram posteriormente secas em estufa de circulação forçada a 65 °C, moídas em moinho tipo Wiley e analisadas para o teor de macronutrientes (N, P, K, Ca, Mg e S), de acordo com Malavolta, Vitti e Oliveira (1997).

3.2.4 Análise univariada dos dados

Para uma primeira visão sobre os efeitos da aplicação do nitrogênio na resposta espectral da cana-de-açúcar, foram calculados os coeficientes de correlação de Pearson, entre cada comprimento de onda e o teor foliar de nitrogênio (TFN). As significâncias das correlações foram avaliadas utilizando o teste t ($p \leq 0,05$).

3.2.5 Análise de componentes principais

Visando explicar as alterações multivariadas nos dados hiperespectrais, foi implementada a análise de componentes principais (ACP) utilizando o algoritmo iterativo NIPALS (MARTENS; NAES, 1989) onde as variáveis dependentes (X), no caso os resultados de reflectância para cada comprimento de onda, são submetidas à equação (1).

$$X = t_1 P'_1 + \dots + t_k P'_k + \varepsilon_k \quad (1)$$

Sendo que t é um vetor de pontuação (“scores”), P são os pesos de cada comprimento de onda (“loadings”) e ε são os resíduos para o k_n componente. O algoritmo extrai um componente principal por vez e cada componente é obtido iterativamente por repetidas regressões de X em t para obter melhores P , e de X em P para obter melhores t . Este procedimento é utilizado em análises multivariadas para se reduzir o número de variáveis preditoras e/ou para descrever quais variáveis são mais importantes para cada componente principal e como estes estão relacionados com a variável independente. Posteriormente os resultados dos “scores” dos componentes principais que representam as variâncias dos dados, foram discutidos em relação a outras variáveis, como área e safras avaliadas.

3.2.6 Análise de regressão simples utilizando índices de vegetação citados em literatura

Foi realizado o levantamento bibliográfico de índices espectrais da vegetação, já apontados na literatura como sensíveis a variação de nitrogênio ou pigmentos fotossinteticamente ativos. Com base nos dados hiperespectrais coletados, foram realizados os cálculos destes índices, seguindo a definição de seus autores (Tabela 3).

Tabela 3 - Índices espectrais encontrados na literatura e serem testados em relação a capacidade de estimar o teor foliar de nitrogênio em cana-de-açúcar

Sigla	Descrição	Fórmula	Autor
BNi	Buschman and Nagel index	$Bni = \frac{(R750-R500)}{(R705-R500)}$	(BUSCHMANN, 1993)
GMi1	Gitelson and Merzlyak index-1	$GMi1 = \frac{R750}{R550}$	(GITELSON; MERZLYAK, 1994)
GMi2	Gitelson and Merzlyak index-2	$GMi2 = \frac{R750}{700}$	(GITELSON; MERZLYAK, 1994)
GNDVI	Green Normalized Difference Vegetation Index	$GNDVI = \frac{(R780-R550)}{(R780+R550)}$	(APARICIO et al., 2000)
mND ₇₀₅	Modified Normal Difference Index	$mND_{705} = \frac{(R750-R705)}{(R750+R705-2R500)}$	(SIMS; GAMON, 2002)
MTCI	MERIS terrestrial chlorophyll index	$MTCI = \frac{(R750-R710)}{(R710-R680)}$	(DASH; CURRAN, 2004)
NDCI	Normalized Difference Chlorophyll Index	$NDCI = \frac{(R762-R527)}{(R762+R527)}$	(MARSHAK et al., 2000)
NDRE	Normalized Difference red edge	$NDRE = \frac{(R790-R720)}{(R790+R720)}$	(RODRIGUEZ et al., 2006)
PSNDa	Pigment Specific Normalized Difference a	$PSNDa = \frac{(R800-R680)}{(R800+R680)}$	(BLACKBURN, 1998)
PSNDb	Pigment Specific Normalized Difference b	$PSNDb = \frac{(R800-R635)}{(R800+R635)}$	(BLACKBURN, 1998)
PSNDc	Pigment Specific Normalized Difference c	$PSNDc = \frac{(R800-R470)}{(R800+R470)}$	(BLACKBURN, 1998)
RI-1dB	Ratio Index – 1dB	$RI-1dB = \frac{R735}{R720}$	(GUPTA; VIJAYAN; PRASAD, 2003)
RI-2dB	Ratio Index – 2dB	$RI-2dB = \frac{R738}{R720}$	(GUPTA; VIJAYAN; PRASAD, 2003)
RI-3dB	Ratio Index – 3dB	$RI-3dB = \frac{R741}{R717}$	(GUPTA; VIJAYAN; PRASAD, 2003)
RI-half	Ratio Index – half	$RI-half = \frac{R747}{R708}$	(GUPTA; VIJAYAN; PRASAD, 2003)
RNDVI	Red Normalized Difference Vegetation Index	$RNDVI = \frac{(R780-R670)}{(R780+R670)}$	(RAUN et al., 2001)
SR ₇₀₅	Simple Ratio 705	$SR705 = \frac{R750}{R705}$	(GITELSON; MERZLYAK, 1994)
VOGa	Vogelman Index a	$VOGa = \frac{R740}{R720}$	(VOGELMANN; ROCK; MOSS, 1993)
VOGb	Vogelman Index b	$VOGb = \frac{(R734-R747)}{(R715-R726)}$	(VOGELMANN; ROCK; MOSS, 1993)
VOGc	Vogelman Index c	$VOGc = \frac{(R734-R747)}{(R715-R720)}$	(VOGELMANN; ROCK; MOSS, 1993)

Os valores calculados para os índices foram então submetidos a análise de regressão linear simples (SLR) como variáveis dependentes, sendo variáveis independentes os

resultados do TFN calculados em laboratório. Os modelos foram calibrados com os dados coletados por variedade na safra 2012/13 ($n = 24$) e validados com os resultados obtidos na avaliação na safra 2013/14 ($n = 24$)

3.2.7 Seleção de variáveis e análise de regressão linear múltipla por “stepwise”

Pré-tratamento dos dados

Foram utilizados dados espectrais da folha de cana-de-açúcar no intervalo de 500 a 1000 nm apenas. Comprimentos de onda menores que 500 nm obtidos pela esfera integradora modelo RTS-3ZC, apresentaram elevado grau de ruído, e sua utilização influenciou negativamente a estabilidade final dos modelos. Por outro lado, comprimentos de onda maiores que 1000 nm, não apresentaram melhorias significativas aos modelos finais, e afim de otimizar o processamento dos dados os mesmos também não foram utilizados.

Os dados utilizados foram as curvas espectrais médias de reflectância por parcela e a partir destas foram também calculadas as curvas da primeira derivada do espectro (PDE), por meio da eq. (2)

$$PDE = R_{\lambda(j+1)} - R_{\lambda(j)} / \Delta\lambda \quad (2)$$

Em que $R_{\lambda(j)}$ é a reflectância no comprimento de onda j , $R_{\lambda(j+1)}$ a reflectância no comprimento de onda $j+1$ e $\Delta\lambda$ é a diferença (nm) entre os comprimentos de onda j e $j+1$. Na Figura 2 pode-se observar as curvas médias de reflectância e PDE utilizados no presente trabalho.




Figura 2 - Curvas espectrais médias de reflectância (a) e primeira derivada do espectro (b), para as doses 0 e 100 kg ha⁻¹, utilizadas no presente trabalho

Redução de dimensão e seleção de variáveis

Um dos grandes problemas práticos ao se trabalhar com dados multivariados, onde o número de observações é maior que o número de variáveis preditoras, ou mesmo quando estas são altamente correlacionadas entre si. A metodologia “*sparse partial least square*” (sPLS), tem como princípio central a imposição de dispersão (“*sparsity*”) nas variáveis preditoras, por meio dos princípios dos mínimos quadrados parciais, permitindo eficiente redução e seleção de variáveis (CHUN; KELES, 2010). Esta metodologia foi implementada utilizando o pacote de análises sPLS, desenvolvido para o software estatístico R (CHUNG; CHUN, 2012).

Os resultados desta fase foram calculados utilizando apenas os dados da safra 2012/13, e geraram coeficientes que representam a importância de cada variável preditora (comprimentos de onda) para predição do TFN, sendo que por observação foram selecionados os 15 comprimentos de onda mais importantes, uma vez que a inserção de maior número de variáveis iniciais não ocasionou melhora estatisticamente nos parâmetros dos modelos finais de regressão linear múltipla por “*stepwise*” gerados posteriormente.

Regressão linear múltipla por “*stepwise*” (RLMS)

RLMS foi utilizado para a geração de modelos para estimativa do TFN em cana-de-açúcar. Os modelos de predição foram gerados para os dados de reflectância e da PDE com dados espectrais obtidos na safra 2012/13 e, posteriormente, os modelos foram validados com dados independentes obtidos na safra 2013/14.

A técnica Stepwise (passo a passo), se inicia com um modelo contendo todas as variáveis do conjunto, sendo estas removidas de forma gradativa as variáveis estatisticamente menos significativas. Esse processo ocorre até que as variáveis restantes sejam todas importantes (estatisticamente relevantes), ou seja, até que não haja melhora na significância do modelo ou não haja variáveis a serem retiradas. Essa técnica supõe que algumas variáveis não contribuem de forma expressiva para a resposta de todo o conjunto (DARVISHZADEH et al., 2008).

O melhor modelo foi selecionado com base no menor valor para o critério de informação de akaike (CIA), que leva em consideração qual é a penalização dos parâmetros estatísticos do modelo de regressão em relação a inserção ou exclusão de mais uma variável preditora (ESTES et al., 2008). A análise de CIA não representa diretamente a qualidade do modelo final, mas permite escolher o melhor modelo entre uma série de combinações de variáveis possíveis.

3.2.8 Avaliação da precisão dos modelos gerados

A precisão de todos os modelos gerados nas fases anteriores foi avaliada com base nos resultados do coeficiente de determinação (R^2), raiz quadrada do erro médio (RMSE) e o erro relativo de predição (RE), estes dois últimos calculados pelas equações 3 e 4.

$$\text{RMSE} = \sqrt{\frac{1}{n} \times \sum_{i=1}^n (P_i - O_i)^2} \quad (3)$$

$$\text{RE} = \sqrt{\frac{1}{n} \times \sum_{i=1}^n \left(\frac{P_i - O_i}{O_i} \right)^2} \times 100 \quad (4)$$

Onde P_i e O_i são os valores previstos e observados para o TFN respectivamente e n é o número de observações utilizadas para geração ou validação do modelo.

4. RESULTADOS E DISCUSSÃO

4.1 Resultados para a análise foliar de nitrogênio e balanço hídrico para as áreas experimentais na safra 2012/13 e 2013/14

Os resultados da análise foliar de nitrogênio em função das doses de nitrato de amônio aplicadas (Figura 3), mostram que a variação dos dados foi menor na safra 2012/13, comparada a safra 2013/14. Apesar disto existiu um certo padrão em relação ao comportamento das variedades dentro das áreas quando observadas a variação do TFN entre as safras, com tendência ao aumento dos teores de nitrogênio na folha com o aumento das doses.

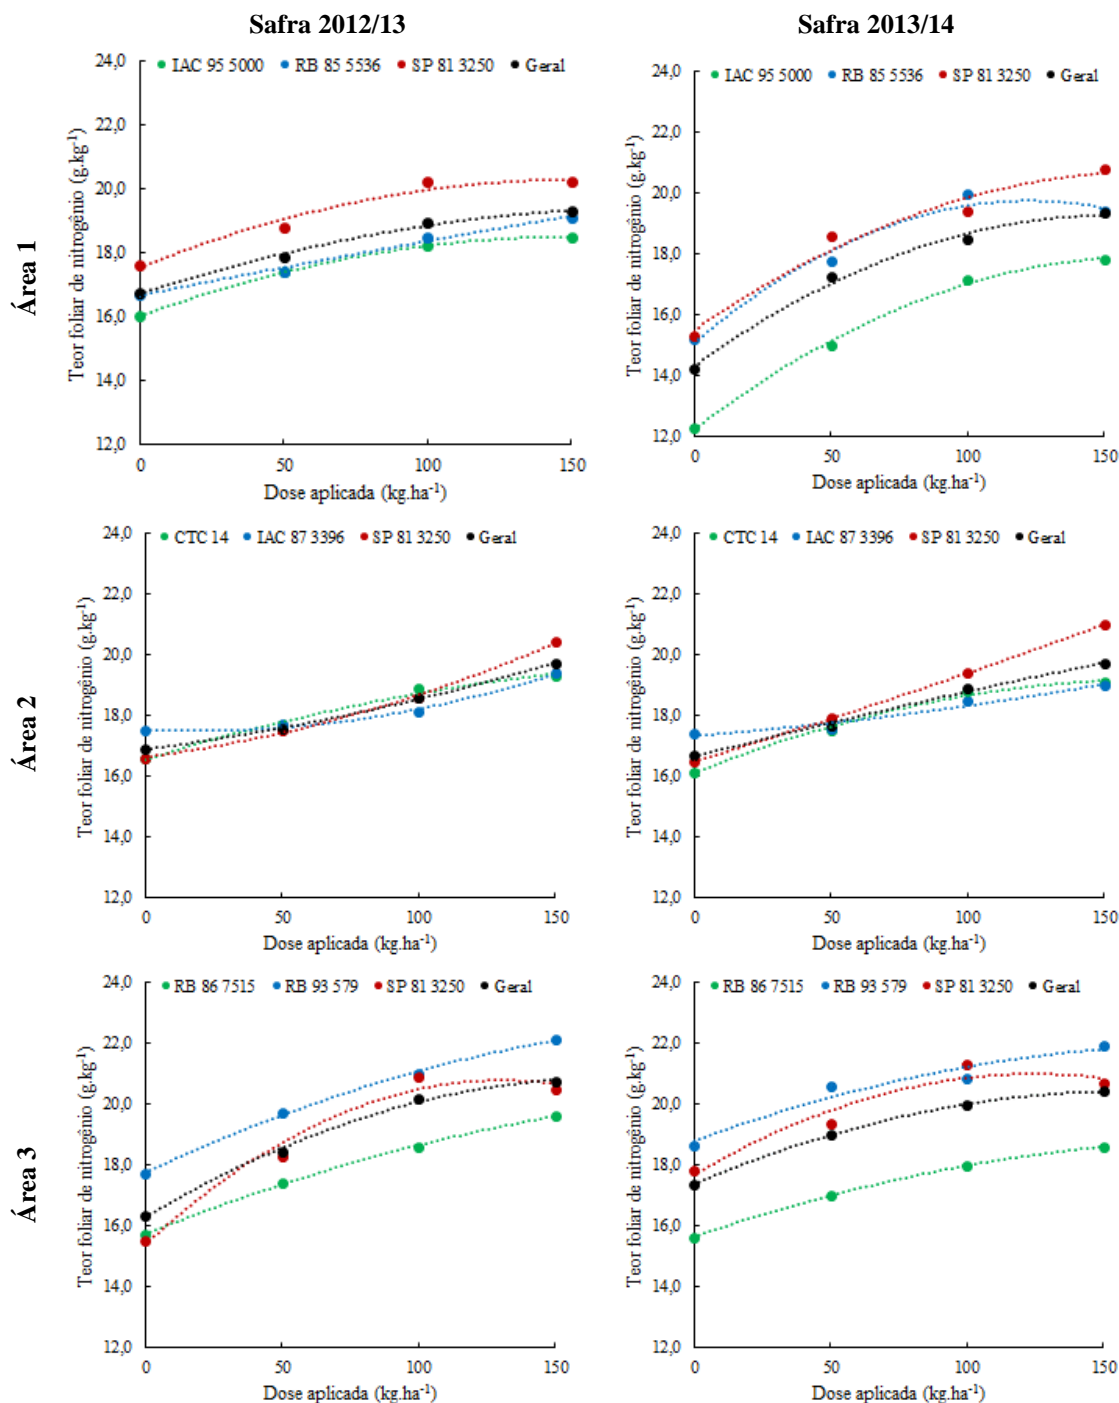


Figura 3 – Teor foliar de nitrogênio (TFN) para as diferentes doses de nitrogênio aplicadas nas safras 2012/13 e 2013/14.

A variedade SP 81 3250 foi a única que mostrou tendência de saturação no TFN, tanto na área 1 na safra 2012/13, quanto na área 3 para ambas as safras, apresentando inclusive menores valores para o TFN na dose de 150 kg ha⁻¹ que na dose de 100 kg ha⁻¹. A área 2 foi a que apresentou as menores variações em relação ao TFN entre as três variedades cultivadas sendo este comportamento observado nas duas safras avaliadas (Figura 3).

Segundo Raij et al. (1997), os valores normais de N na folha de cana-de-açúcar estão entre 18 e 25 g kg⁻¹. Seguindo estes parâmetros os resultados observados apontam que a cultura estava submetida a determinado nível principalmente nos tratamentos com doses de 50 kg ha⁻¹ ou inferiores. Além disto é interessante avaliar que, os níveis foliares de N observados no presente trabalho, mostraram a existência de diferenças entre os valores médios das diversas variedades e sendo assim, os níveis críticos devem ser estudados mais detalhadamente e faixas de estresse mais precisas devem ser propostas por variedade ou ambiente de cultivo (SANTOS et al., 2013).

Afim de compreender melhor quais foram as condições climáticas de cultivo durante as safras em avaliação e sua possível influência nos resultados obtidos, foi realizado o cálculo do balanço hídrico (Figura 4), com base na metodologia proposta pela FAO (ALLEN et al., 1998). O eixo horizontal representa o tempo em escala diária e no eixo vertical estão plotados os valores diários de precipitação, da depleção da água no solo e o limite da depleção para que a água esteja prontamente disponível para a cultura (APD) todos em milímetros (mm). Valores de depleção acima da linha vermelha indica que a cultura estava submetida a algum nível de estresse de acordo com as necessidades hídricas da cultura.

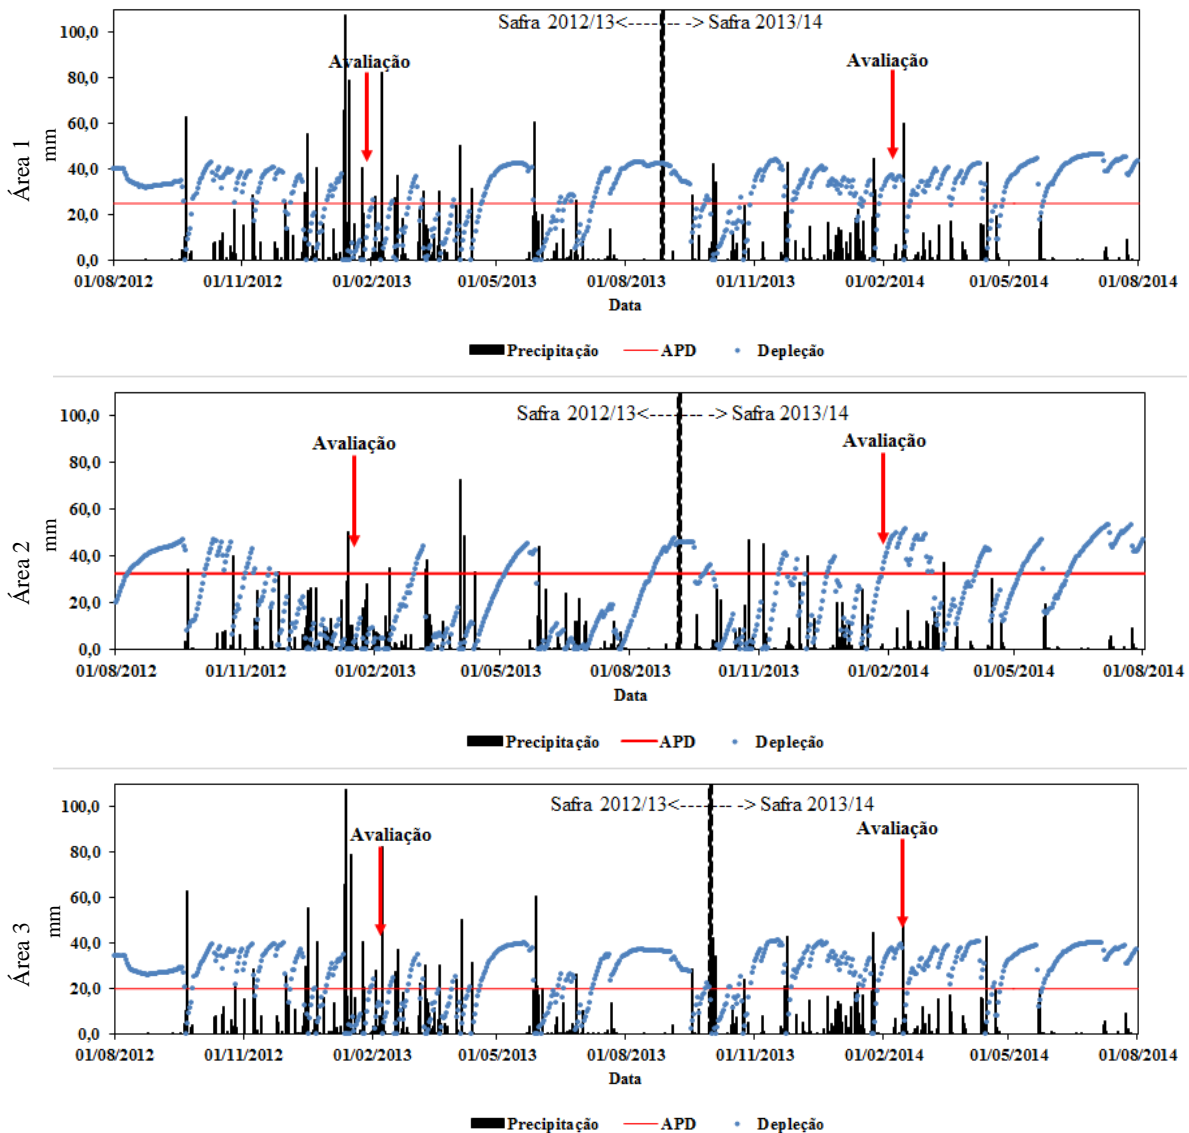


Figura 4 - Balanço hídrico sequencial da cultura da cana-de-açúcar para as três áreas em estudo

Para as três áreas em estudo, observa-se que o volume de precipitação ocorrida do momento da colheita até a data da amostragem foi maior na safra 2012/13 que na safra 2013/14, sendo que os valores acumulados foram respectivamente de 890,0 e 541,6 mm para a área 1, 565,6 e 466,1 mm para a área 2 e 682,4 e 555,4 mm para a área 3. De acordo com os resultados do balanço hídrico, nenhuma das áreas apresentavam déficit hídrico no momento da coleta para a safra 2012/13, já para a safra 2013/14, todas elas apresentaram algum nível de déficit hídrico (Figura 4).

Tendo em vista que quase que em sua totalidade o nitrogênio absorvido pelas plantas se dá por meio do fluxo de massa, a ocorrência de estresse hídrico pode explicar a maior variabilidade do TFN observado na safra 2013/14 quando comparada com a 2012/13.

Ao mesmo tempo que a escassez de água no solo pode ocasionar alterações na dinâmica de absorção no nitrogênio pela planta de cana-de-açúcar, o estresse hídrico altera significativamente o comportamento espectral da vegetação em toda a faixa do espectro avaliada no presente trabalho, que vai da região do visível ao infravermelho de ondas curtas (ZYGIELBAUM et al., 2009; BANDYOPADHYAY et al., 2014).

A escassez de água pode causar modificações no arranjo das estruturas fotossinteticamente ativas (ZYGIELBAUM et al., 2012), que governam a reflectância principalmente da região do visível e “*red-edge*”, tendo estas estreita relação com o nitrogênio na planta (CAMMARANO et al., 2014).

4.2 Análise de bandas individuais utilizando os resultados de todas as variedades e áreas experimentais combinadas

Visando melhorar a apresentação visual, na Figura 5 estão apresentadas apenas as curvas espectrais médias para as doses de nitrogênio 0 e 100 kg ha⁻¹. Pode-se observar diferenças entre o comportamento espectral das folhas de cana-de-açúcar, quando comparadas as curvas médias dos tratamentos com e sem aplicação de nitrogênio sendo que, para a região espectral dos visível (400 a 700 nm), as folhas de plantas adequadamente nutridas, mostraram menores valores de reflectância, com comportamento inverso para a região do infravermelho próximo (750 a 950 nm).

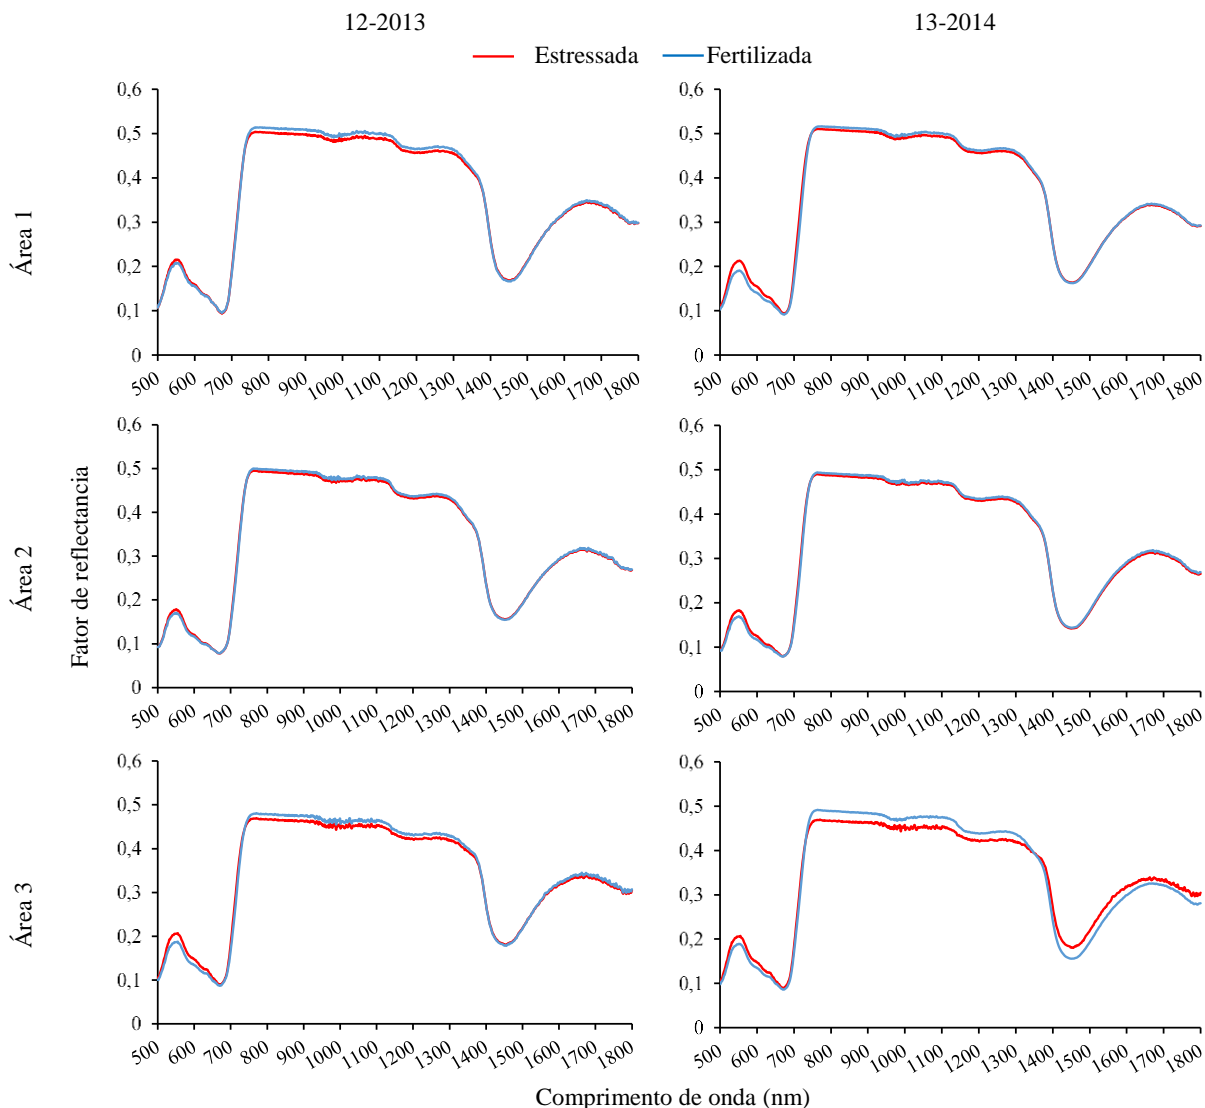


Figura 5 - Resposta espectral média das folhas de cana-de-açúcar para as doses 0 e 100 kg ha⁻¹ de nitrato de amônio, nas três áreas experimentais avaliadas nas safras 12/2013 e 13/2014.

Apesar deste comportamento ser persistente, apresentam diferentes intensidades entre as áreas e safras analisadas, sendo que para ambos os anos, a área experimental de Piracicaba (Área 2), que possui o solo com maiores teores de argila entre os experimentos (Tabela 1), apresentou as menores diferenciações visuais em relação a intensidade de reflectância, sendo que as maiores diferenciações foram observadas na área de Santa Maria da Serra (Área 3), que possui um solo arenoso, de baixa fertilidade natural.

Sobre este comportamento, a região do visível, é sensível a alterações na concentração de pigmentos na folha, sendo a clorofila, a mais abundante em plantas verdes (XUE; YANG, 2009). Folhas saudáveis apresentam uma feição de reflectância típica, centrada em 550 nm (região do verde), uma vez que a luz verde é absorvida em menores quantidades quando comparadas com a luz azul e vermelha, sendo a luz verde predominante em relação a energia refletida e transmitida para esta faixa do espectro. No entanto, a absorção de energia pela

cultura na região do verde é considerável, e aumenta com o incremento da concentração de clorofila na folha, que por sua vez é diretamente sensível a captação de nitrogênio pela planta (TERASHIMA et al., 2009).

Conclui-se que plantas estressadas tendem a apresentar folhas com tonalidade verde clara a amarelada, enquanto que plantas bem nutridas, tendem a apresentar folhas com tonalidades verde escuras. A concentração de outros pigmentos como carotenoides, xantofilas e antocianinas também ocasionam variações no comportamento espectral da região do visível.

Os pigmentos da folha são praticamente “transparentes” a radiação eletromagnética na região do infravermelho próximo, sendo que o comportamento espectral desta região sofre grande influência do arranjo estrutural das células do mesófilo esponjoso (KNIPLING, 1970).

Grande parte do nitrogênio na planta é alocado na composição dos cloroplastos, outra parte considerável deste elemento, encontra-se como constituinte de aminoácidos livres na planta, proteínas ou na estrutura de outros componentes nitrogenados, como as bases nitrogenadas (purinas e pirimidinas) e ácidos nucleicos (DNA e RNA), que são responsáveis por 10% do nitrogênio total da planta. Outras formas amino solúveis podem representar até 5% do nitrogênio na planta (CONN et al., 1987; MENGEL; KIRKBY, 1987).

Estando o nitrogênio relacionado com os mais importantes processos fisiológicos que ocorrem nas plantas, estresses causados por este nutriente podem afetar a estrutura celular, e conseqüentemente a reflectância no infravermelho próximo. Neste trabalho, foi observado que o incremento nas doses de nitrogênio, ocasionou aumento da reflectância no infravermelho próximo (Figura 3). Não foram observadas alterações sistemáticas na região do infravermelho de ondas curtas (950 a 2200 nm) relacionados à aplicação de doses de nitrogênio, sendo esta região espectral descrita na literatura como primariamente responsiva a variações no conteúdo de água da folha (CECCATO et al., 2001).

Os resultados observados dos coeficientes de correlação de Pearson entre cada comprimento de onda e o TFN são apresentados na Figura 6. Esta análise mostra que existe uma correlação significativa e consistente entre o TFN e a reflectância da folha para a região do visível, especialmente nos comprimentos de onda da luz verde, centrada em 550 nm, cujos coeficientes variaram de -0,40 a -0,48 na safra 2012/13 e de -0,31 a -0,64 na safra 2013/14.

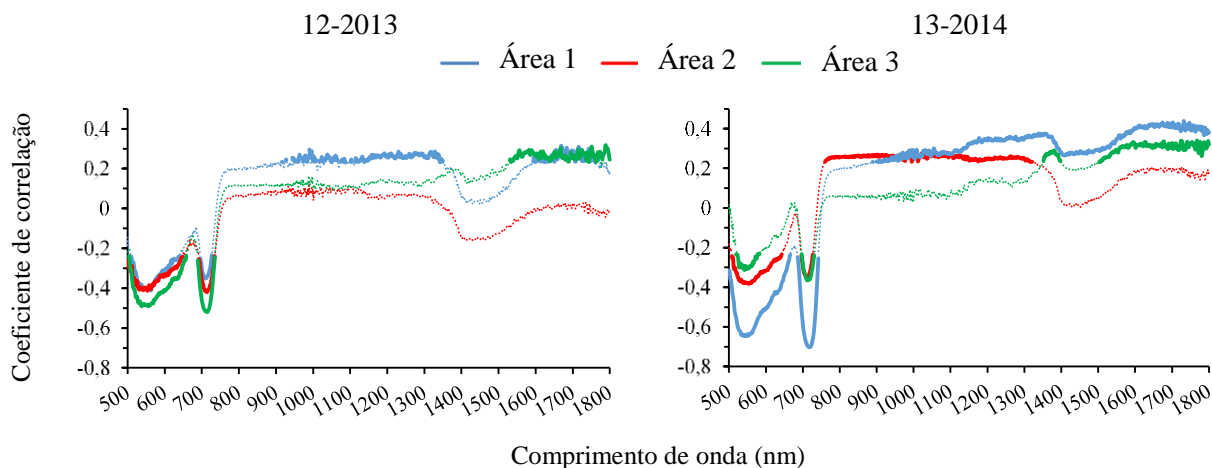


Figura 6 - Coeficientes de correlação de Pearson entre cada comprimento de onda da curva espectral da cana-de-açúcar e o teor foliar de nitrogênio (TFN) englobando todas as doses, variedades e áreas experimentais nas safras 2012/13 e 2013/14. Linhas contínuas indicam correlação significativa, de acordo com o teste t ($p \leq 0,05$)

A região de transição entre a luz visível e o infravermelho, caracterizada pela rampa e rápido aumento da reflectância, observada na curva espectral da vegetação e descrita na literatura como “*red-edge*” (TIAN et al., 2011b), também apresentou correlação consistente e significativa com o TFN, estando estes valores entre -0,36 e -0,52 na safra 2012/13 e -0,35 e -0,70 na safra 2013/14. Tanto a região espectral da luz verde quanto o “*red-edge*” têm sido citadas constantemente como sensíveis a variação de pigmentos em plantas, especialmente a clorofila; portanto, índices e modelos espectrais têm sido desenvolvidos utilizando estas regiões espectrais (YAO et al., 2013; CAMMARANO et al., 2014).

É possível observar que a região do infravermelho próximo, para a safra 2012/13, apenas apresenta correlação significativa com o TFN na área 1, no entanto, os coeficientes são baixos, sempre menores que 0,30 (Figura 6). Para a safra 2013-14, tanto a área 1 quanto a 2 apresentaram correlações significativas, porém com valores também baixos, próximos aqueles citados anteriormente.

A região do infravermelho de ondas curtas, também apresentaram resultados inconsistentes no que diz respeito a correlação entre o TFN e a reflectância nestes comprimentos de onda. Estes resultados indicam que estas regiões espectrais são mais sensíveis a outros tipos de estresses nas plantas, podendo apresentar alguma correlação com o TFN, quando outros fatores de produção não atingem níveis limitantes, fatores tais quais, deficiência de outros nutrientes, doenças e pragas, ou mais provável neste caso a variação na disponibilidade hídrica dos solos, uma vez que para todas áreas experimentais não foram utilizadas tecnologias de irrigação, situação mais comum para o sistema produtivo de cana-de-açúcar brasileiro.

4.3 Análise de componentes principais para os dados das três áreas experimentais incorporando todas as doses e variedades

Para uma análise multidimensional dos dados foi utilizada a análise de componentes principais, que tem como objetivo resumir a maior parte da informação original (nesse caso a curva espectral), a um número mínimo de fatores para fins de detecção da variabilidade dos dados, observação de variáveis notáveis e mesmo previsão do TFN.

A Figura 7 apresenta os resultados dos “loadings” calculados na análise de componentes principais (ACP), mostram que o componente principal 1 (CP1) explica 99,928% da variabilidade de todo o conjunto de dados em questão. Este componente claramente está relacionado a variações globais na intensidade de reflectância das curvas espectrais, pois suas feições acompanham perfeitamente a tendência de um espectro normal da cana-de-açúcar.

Apesar de explicar quase que em sua totalidade a variação global dos dados, o CP1 não apresentou correlação significativa com o TFN ($r = 0,04$), indicando que a maior parte da variabilidade dos dados está mais relacionada a outros fatores, tais quais: o ambiente de cultivo, variedades avaliadas, condições climáticas prévias ou na época de avaliação ou até mesmo variações dos espectros decorrente de instabilidade do próprio equipamento, como observado por Ben-Dor, Ong e Lau (2015), estudando a aplicação da radiometria para análise de solos em laboratório.

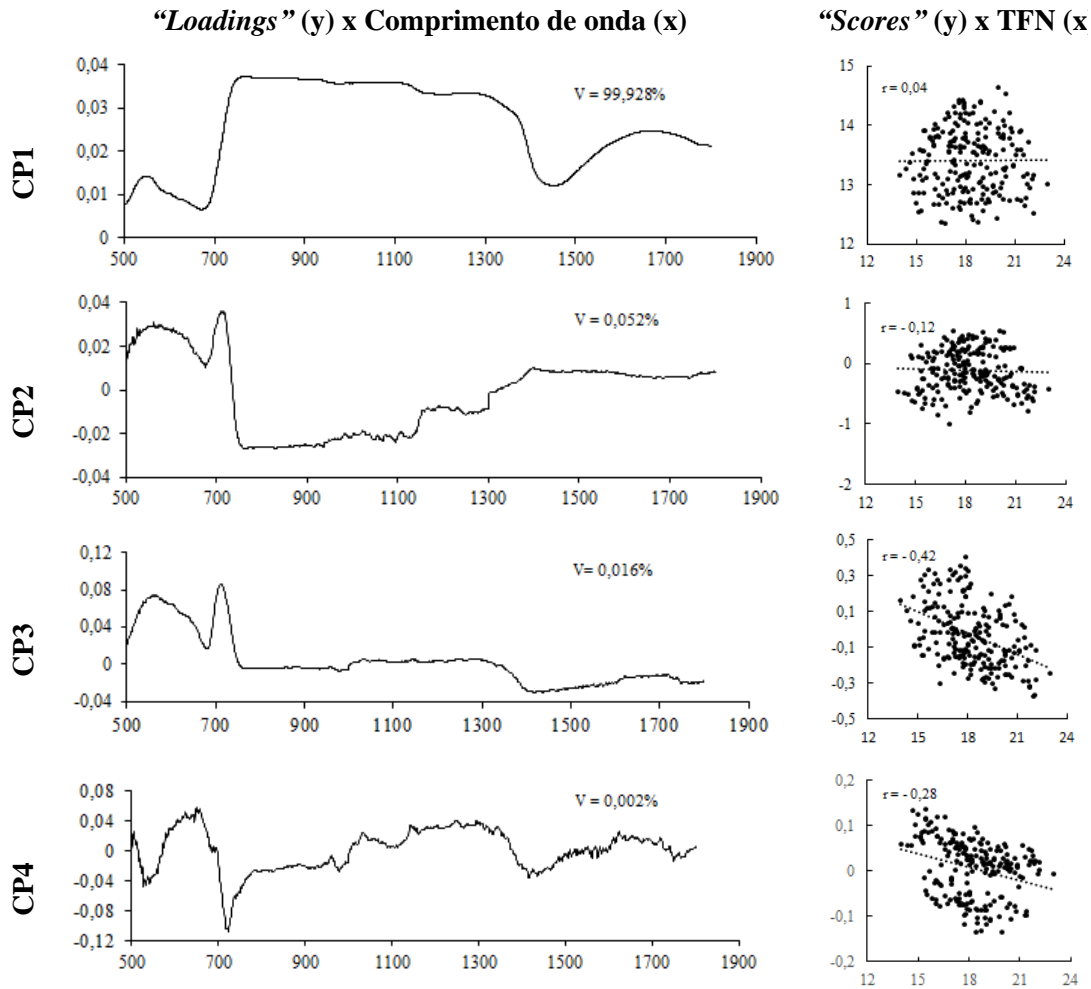


Figura 7 - Resultados dos “loadings” e “scores” para análise de componentes principais (ACP) para os dados hiperespectrais de cana de açúcar nas três áreas de estudo. V = percentual da variância dos dados explicado por cada componente principal e r = coeficiente de correlação de Pearson entre os “scores” calculados para cada curva espectral e o teor foliar de nitrogênio (TFN).

Já o CP2, apresenta valores positivos de “loadings” nos comprimentos de onda do visível, principalmente no verde e também na região de transição entre o visível e o infravermelho, denominada “red-edge”, enquanto que na região do infravermelho próximo, os valores de “loadings” observados foram negativos, porém com valores menores (Figura 5). Acima de 1400 nm os valores dos “loadings” são próximos a zero. Apesar do coeficiente baixo ($r = -0,12$), este componente principal apresentou correlação significativa com o TFN de acordo com o teste t a 5% de probabilidade.

O componente principal 3 (CP3), apresentou resultados parecidos com os observados no CP2 para a região do visível, no entanto o peso dos “loadings” para todos os comprimentos de onda acima de 750 nm apresentam valores próximos a zero (Figura 7). Este componente principal apresentou a maior correlação com os valores do TFN ($r = -0,42$).

Fazendo uma análise paralela entre esta correlação dos resultados dos “loadings” para o CP3 (Figura 7) com as correlações dos comprimentos de onda e o TFN (Figura 6), observa-se que existe uma coerência entre os resultados apresentados, uma vez que as curvas espectrais da folha das plantas que não receberam aplicação de nitrogênio apresentaram correlação negativa com a reflectância da região do visível e do “red-edge”.

O componente principal 4 (CP4) também apresentou valores significativos de correlação em relação ao TFN ($r = -0,28$). Os resultados dos “loadings” apresentam valores negativos para a região do verde, positivo para a região do vermelho, porém com valores baixos, sendo que a região do infravermelho próximo e de ondas curtas apresenta valores próximos a zero (Figura 7).

Os valores mais expressivos de “loadings” para o CP4, são observados na estreita faixa do “red-edge” (680 a 720 nm), o que explica o motivo deste componente principal estar mais relacionado as variações globais do TFN, uma vez que os resultados das correlações entre o TFN com as bandas individuais (Figura 6), mostraram que nesta região do espectro foram observadas as melhores correlações, bem como foi a região mais estável entre as áreas e safras avaliadas.

Cammarano et al. (2014) estudando a aplicabilidade de dados espectrais para a predição do teor de nitrogênio em plantas de trigo desenvolvidas na região do mediterrâneo, já haviam apontado que os melhores e mais estáveis índices de vegetação para modelagem desta variável, foram aqueles compostos por comprimentos de onda do “red-edge”, e os resultados apresentados até aqui, mostram que a cultura da cana-de-açúcar tem comportamento semelhante em relação as regiões do espectro mais sensíveis a variações no TFN.

Os resultados dos “scores” do CP1 e CP2 para todo o conjunto de dados em estudo, estão apresentados em forma de gráfico de dispersão (Figura 6). É possível observar que em geral existe uma tendência de separação entre os dados espectrais das três áreas em estudo, e nos gráficos para as diferentes safras, existe maior dispersão dos dados da safra 2012/13, principalmente para a área 3 (Santa Maria da Serra).

Apesar disso, existe um padrão de comportamento das respostas espectrais dentro das áreas, sendo que em relação ao CP1, a área 1, apresentou os maiores valores de “scores” (Em média 7,3), observados no eixo y da Figura 8, e estando este componente principal ligado diretamente as diferenças de intensidade de reflectância, conclui-se que a área 1, teve a tendência de apresentar maiores valores de reflectância, já entre as áreas 2 e 3, não se observa grandes diferenças em relação aos valores do CP1 (Figura 8). Por outro lado, em relação ao CP2, que representa as variações da reflectância principalmente na região do visível e

infravermelho próximo, com valores de “loadings” positivos para a primeira e negativa para a segunda região do espectro, como já apresentado (Figura 7), separou a área 1 das demais, que apresentaram valores semelhantes (Figura 8).

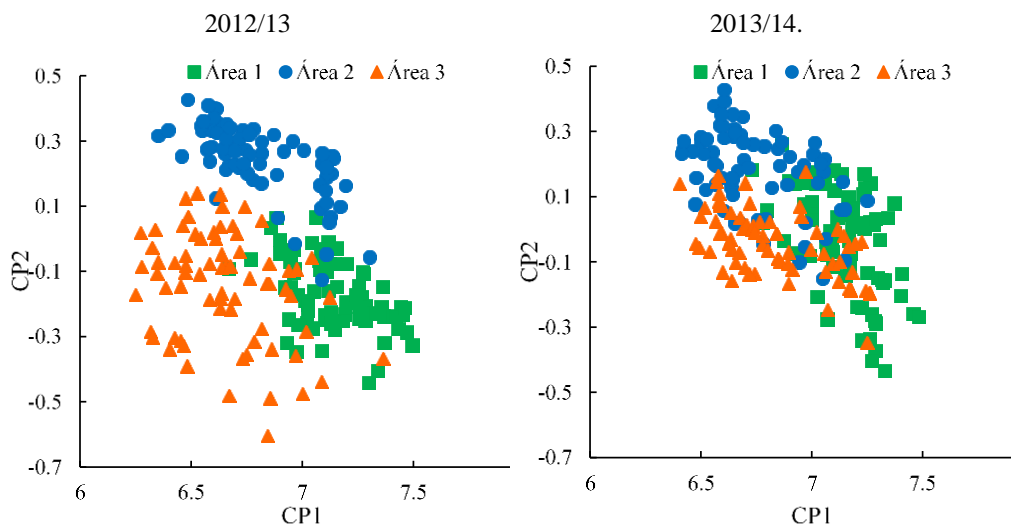


Figura 8 - Dispersão dos “scores” entre os componentes principais 1 e 2 (CP1 e CP2) para os dados das três áreas em estudo. Área 1= Jaú, Área 2 = Piracicaba, Área 3 = Santa Maria da Serra

O fato da repetição dos padrões de comportamento dos “scores” para os componentes principais 1 e 2, entre as áreas em estudo para as safras consecutivas, aliado ao agrupamento das áreas em cada safra, mesmo sendo estas compostas por três variedades e quatro doses de nitrogênio, mostra que, mesmo com estudos a nível foliar, o ambiente de cultivo tem uma influência significativa na resposta espectral da cultura da cana-de-açúcar, que neste caso se sobressaiu mesmo em relação às diferenças espectrais das variedades e as variações das condições atmosféricas em que a cultura estava submetida no decorrer da safra e no momento da coleta das amostras foliares.

Ao se avaliar os resultados da análise de componentes principais das variedades cultivadas dentro de cada área experimental nas duas safras em estudo (Figura 9), é possível verificar que em geral existem diferenças entre das curvas espectrais de diferentes variedades, e que em geral, o comportamento das variedades segue um padrão dentro das safras estudadas. A variedade SP 81 3250, sempre apresentou os maiores valores dos “scores” calculados para o CP1, o que significa que esta variedade apresenta em geral maior intensidade de reflectância, com exceção da variedade IAC 95 5000, cultivada na área 1, que apresentou comportamento semelhante a SP 81 3250, tanto em relação ao CP1 quanto ao CP2.

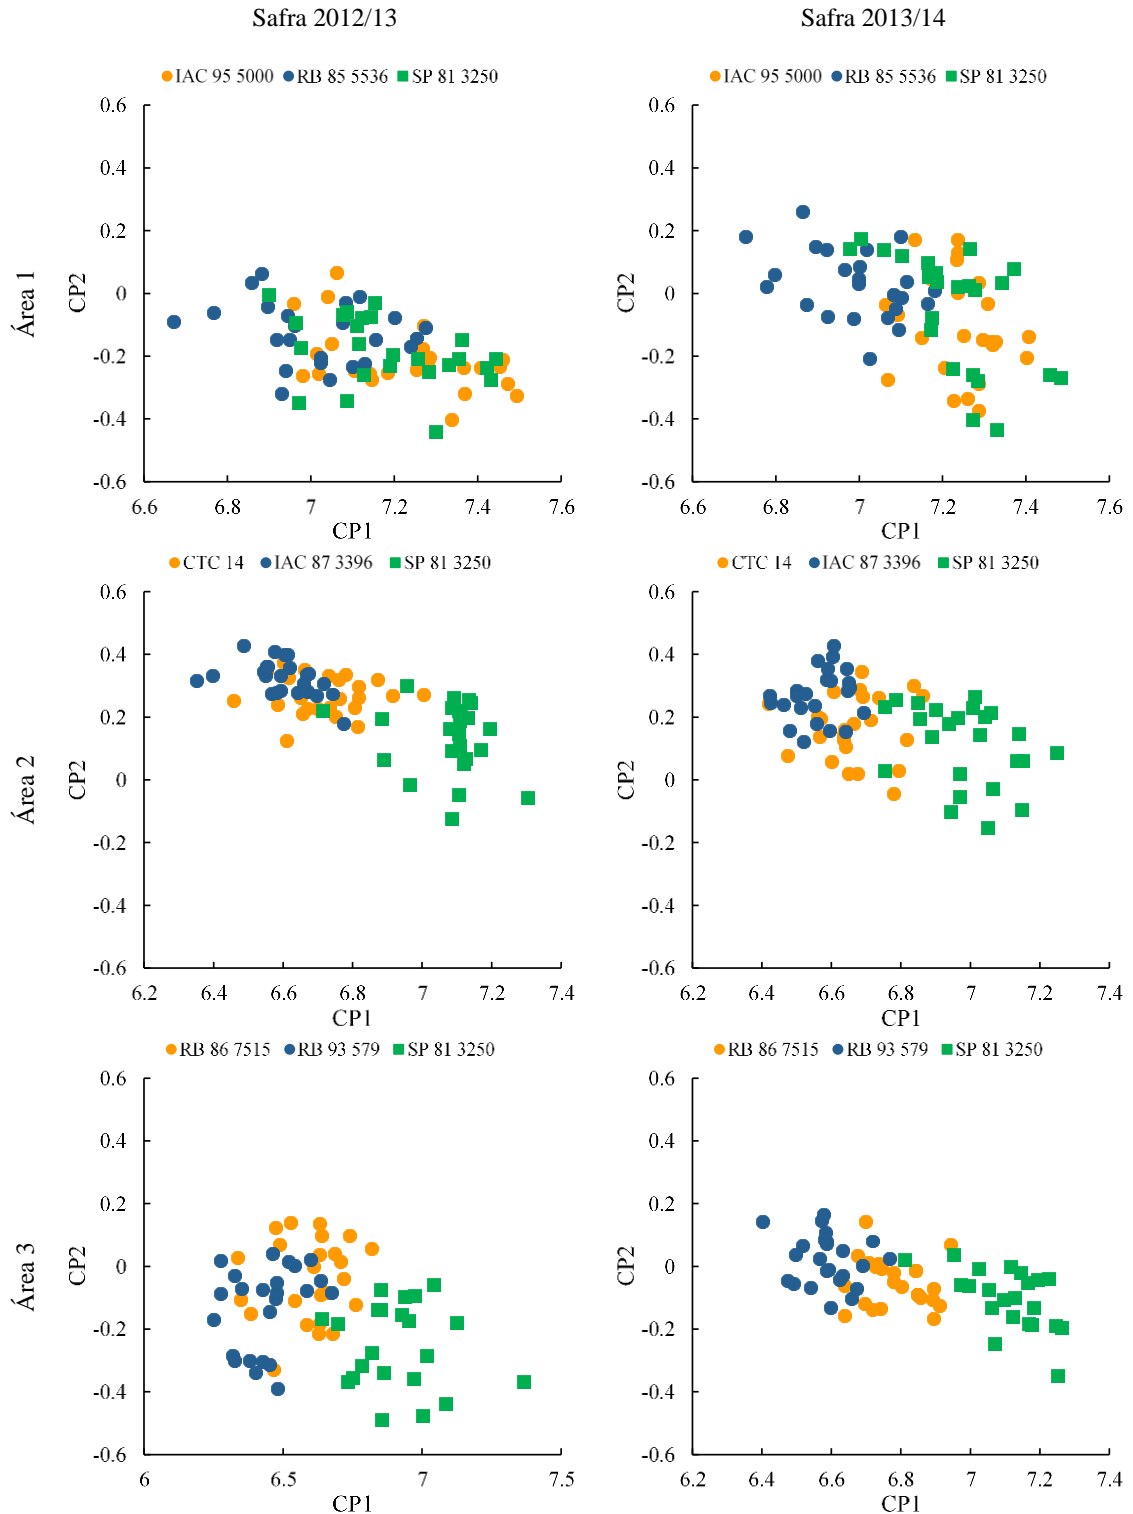


Figura 9 - Gráfico de dispersão entre os componentes principais 1 e 2 (CP1 e CP2) para as três variedades dentro de cada área, nas safras 2012/13 e 2013/14

Sendo a variedade SP 81 3250, comum em todas as áreas experimentais, é possível analisar seu comportamento quando cultivada em diferentes ambientes. Esta variedade em todas as áreas, apesar das variações nos valores absolutos dos “scores”, apresentou os maiores

valores referente ao CP1 e os menores valores em relação ao CP2 quando comparada as demais variedades cultivadas (Figura 9).

Esta consistência de comportamento reforça a tese de que embora existam diferenças do comportamento espectral da cana-de-açúcar, principalmente na intensidade de reflectância ligadas principalmente ao fator clima e ambiente, existem variações sistemáticas que vão além da intensidade de reflectância, que podem ser utilizadas para criar assinaturas espectrais para classificação/separação de variedades ou grupos de variedades semelhantes.

4.4 Performance dos índices de vegetação, levantados em literatura para predição do teor foliar de nitrogênio.

Devido ao grande número de informações provindas dos 20 índices de vegetação testadas no presente trabalho, serão apresentados aqui apenas os cinco índices mais estáveis em relação a precisão dos modelos gerados, a tabela com os coeficientes de correlação para todos os índices é apresentada no Anexo A.

Os resultados para os cinco índices espectrais mais estáveis entre todas as áreas e variedades em estudo (BNi, GNDVI, NDRE, RI-1db e VOGa), podem ser visualizados na tabela 3. Na fase de calibração dos modelos de regressão simples, os índices selecionados, mostraram desempenhos semelhantes e todos os modelos gerados mostraram significância a 1% de probabilidade. Estes índices têm em comum o fato de serem calculados utilizando comprimentos de onda da região do visível (mais precisamente nos comprimentos de onda do verde) e na região do “*red-edge*”, combinados com comprimentos de onda do infravermelho próximo.

Tabela 3 - Resultado da calibração e validação dos cinco índices com melhor desempenho neste estudo para predição do Teor Foliar de Nitrogênio nas diferentes variedades.

Área	Variedade	Índice	Calibração				Validação		
			Equação ^a	R ² _{aj}	RMSE (g kg ⁻¹)	RE (%)	R ² _{aj}	RMSE	RE
Área 1	IAC 95 5000	BNI	Y = 56,52 + BNI x -94,52	0,92	0,34	6,9	0,70	3,50	22,2
		GNDVI	Y = -22,70 + GNDVI x 96,64	0,89	0,41	8,2	0,69	3,67	23,1
		NDRE	Y = -3,97 + NDRE x 116,31	0,89	0,41	8,2	0,74	3,18	20,6
		RI-1db	Y = -77,24 + RI-1db x 71,76	0,88	0,42	8,4	0,69	3,66	23,1
		VOGa	Y = -61,28 + VOGA x 57,21	0,88	0,42	8,4	0,70	3,44	22,1
	RB 85 5536	BNI	Y = 46,00 + BNI x -69,83	0,84	0,49	10,0	0,66	2,50	25,6
		GNDVI	Y = -11,48 + GNDVI x 68,75	0,84	0,50	10,2	0,65	2,50	25,6
		NDRE	Y = 0,04 + NDRE x 90,49	0,81	0,55	11,2	0,76	1,67	20,4
		RI-1db	Y = -54,57 + RI-1db x 54,20	0,80	0,55	11,2	0,70	1,84	21,2
		VOGa	Y = -40,53 + VOGA x 41,65	0,80	0,56	11,4	0,72	1,51	19,3
	SP 81 3250	BNI	Y = 58,15 + BNI x -95,92	0,76	0,80	11,8	0,82	2,93	25,6
		GNDVI	Y = -19,69 + GNDVI x 91,30	0,79	0,75	11,0	0,82	2,69	24,4
		NDRE	Y = -7,03 + NDRE x 138,33	0,71	0,87	12,8	0,77	3,27	26,5
		RI-1db	Y = -81,97 + RI-1db x 75,99	0,69	0,90	13,2	0,84	2,80	24,7
		VOGa	Y = -65,27 + VOGA x 60,24	0,71	0,87	12,8	0,85	3,22	26,7
Área 2	CTC 14	BNI	Y = 64,55 + BNI x -135,02	0,81	0,74	8,4	0,80	2,35	24,0
		GNDVI	Y = -42,03 + GNDVI x 122,99	0,81	0,74	8,4	0,80	1,74	20,0
		NDRE	Y = -8,28 + NDRE x 106,27	0,79	0,78	8,9	0,74	2,78	25,8
		RI-1db	Y = -75,43 + RI-1db x 65,76	0,82	0,72	8,2	0,79	2,07	21,9
		VOGa	Y = -55,50 + VOGA x 48,29	0,82	0,73	8,3	0,79	2,50	24,3
	IAC 87 3396	BNI	Y = 54,62 + BNI x -109,84	0,89	0,39	6,8	0,66	1,00	15,7
		GNDVI	Y = -31,32 + GNDVI x 98,52	0,89	0,39	6,8	0,67	1,00	15,7
		NDRE	Y = -6,49 + NDRE x 95,56	0,85	0,46	9,2	0,68	1,19	16,7
		RI-1db	Y = -59,27 + RI-1db x 54,02	0,86	0,45	9,0	0,69	0,92	15,1
		VOGa	Y = -44,97 + VOGA x 41,04	0,87	0,44	8,8	0,69	0,95	15,4
	SP 81 3250	BNI	Y = 42,84 + BNI x -66,95	0,72	0,91	14,0	0,81	1,06	15,4
		GNDVI	Y = -13,22 + GNDVI x 68,03	0,74	0,87	13,4	0,81	1,02	15,3
		NDRE	Y = 0,71 + NDRE x 77,85	0,77	0,83	12,3	0,82	1,53	17,8
		RI-1db	Y = -42,77 + RI-1db x 44,23	0,74	0,87	13,4	0,82	1,02	15,3
		VOGa	Y = -31,58 + VOGA x 33,94	0,75	0,86	13,2	0,82	1,27	16,4
Área 3	IAC 95 5000	BNI	Y = 44,52 + BNI x -69,35	0,78	0,90	15,0	0,75	0,82	15,0
		GNDVI	Y = -11,96 + GNDVI x 66,97	0,77	0,91	15,2	0,74	0,85	15,1
		NDRE	Y = 2,56 + NDRE x 83,15	0,79	0,87	14,5	0,70	0,92	15,3
		RI-1db	Y = -47,55 + RI-1db x 49,82	0,78	0,90	15,0	0,72	0,87	15,2
		VOGa	Y = -35,15 + VOGA x 38,61	0,77	0,91	15,2	0,75	0,84	14,9
	RB 85 5536	BNI	Y = 47,27 + BNI x -66,78	0,82	0,96	13,7	0,73	0,86	14,4
		GNDVI	Y = -8,34 + GNDVI x 67,30	0,82	0,95	13,6	0,75	0,85	14,4
		NDRE	Y = 4,55 + NDRE x 90,83	0,87	0,82	11,7	0,71	0,89	14,4
		RI-1db	Y = -48,43 + RI-1db x 53,10	0,86	0,84	12,0	0,74	0,87	14,5
		VOGa	Y = -36,92 + VOGA x 42,39	0,86	0,84	12,0	0,78	0,85	14,4
	SP 81 3250	BNI	Y = 46,17 + BNI x -63,88	0,86	0,80	9,6	0,75	0,88	14,4
		GNDVI	Y = -7,65 + GNDVI x 66,00	0,86	0,80	9,6	0,78	0,80	14,1
		NDRE	Y = 5,35 + NDRE x 86,09	0,89	0,70	8,4	0,68	0,90	14,5
		RI-1db	Y = -49,74 + RI-1db x 54,33	0,88	0,73	8,8	0,70	0,89	14,4
		VOGa	Y = -37,63 + VOGA x 43,08	0,89	0,71	8,6	0,72	0,89	14,4

^a Todas as regressões foram significativas pelo teste f (p<0,01).

Entre todos os índices testados, os únicos que não mostraram significância para os modelos na fase de calibração, foram os que utilizavam comprimentos de onda do vermelho ou azul, combinadas a comprimentos de onda do infravermelho próximo, que é o caso por exemplo dos índices PSNDa, PSNDb e PSNDc (Anexo A). As curvas espectrais coletadas com a esfera integradora, modelo RTS-3ZC da ASD, apresentaram elevado grau de ruído nos

comprimentos de onda do azul (350 a 500 nm), o que pode ter afetado os resultados para os índices desenvolvidos nesta região. Apesar destes resultados observados nessa pesquisa, estes índices já foram reportados como úteis na predição do conteúdo de nitrogênio em outras culturas em nível de dossel (MIAO et al., 2009).

Pode-se observar que para a área 1, a variedade IAC 95 5000, apresentou os melhores valores para os parâmetros estatísticos na fase de calibração ($R^2 <0,92 \text{ e } 0,89>$, RMSE $<0,34 \text{ e } 0,42$ e RE $<6,9 \text{ e } 8,4\%>$), seguida da variedade RB 85 5536, SP 81 3250 (Tabela 3). Já para a fase de validação, os valores de R^2 , embora significativos, foram sempre menores comparados a fase de calibração, já os valores observados para a RMSE e RE ($<1,51 \text{ e } 3,77 \text{ g kg}^{-1}>$ e $<19,3 \text{ a } 29,5\%>$ respectivamente), são relativamente altos, sendo que para esta área os modelos calibrados com dados das safras 2012/13, superestimaram o TFN para dados independentes da safra 2013/14.

Na área 2, os resultados da fase de calibração, apresentaram valores variando de $R^2 = 0,72$, RMSE = $0,91 \text{ g kg}^{-1}$ e RE = 14% com o índice BNi na variedade SP 81 3250, a valores de $R^2 = 0,89$, RMSE = $0,39$ e RE = 6,8% com o índice BNi na variedade IAC 87 3396 (Tabela 3). Na fase de validação os modelos se mostraram mais estáveis comparados aos expostos anteriormente para área 1, observando-se para a área 2, variações de 0,66 a 0,82 para R^2 , 0,92 a $2,78 \text{ g kg}^{-1}$ para RMSE e 15,1 a 25,8% para RE. Na área 3, a estabilidade dos modelos foi parecida com a observada na área 2, sendo observados valores de $R^2 <0,77 \text{ e } 0,89>$, RMSE $<0,70 \text{ e } 0,96 \text{ g kg}^{-1}>$ e RE $<8,4 \text{ e } 15,2\%>$ na fase de calibração e $R^2 <0,68 \text{ e } 0,78>$, RMSE $<0,80 \text{ e } 0,92 \text{ g kg}^{-1}>$ e RE $<14,1 \text{ e } 15,3\%>$ na fase de validação.

Existiu grande diferença entre os coeficientes dos modelos gerados para cada variedade individual, não sendo possível calibrar um modelo significativo por área o que impossibilita automaticamente a calibração de um modelo global. Miphokasap et al. (2012), trabalhando com dados hiperespectrais na cultura da cana-de-açúcar na Tailândia já haviam constatado comportamento semelhante, onde modelos calibrados para variedades individuais apresentaram maior estabilidade na fase de validação comparados com modelos mais generalistas.

Amaral et al. (2014) observaram correlação baixa entre resultados de índices de vegetação mensurados por sensores ativos em nível de dossel e o TFN, sendo que não existiu correlação significativa quando dados de várias localidades com diferentes tipos de solos foram adicionados ao modelo, concluindo estes, que a diferença entre as áreas de cultivo, é mais importante que a variabilidade do TFN na cultura da cana-de-açúcar para as condições observadas. No caso deste estudo, mesmo em nível de folha, foi observado que existem

diferenças entre a reflectância de uma mesma variedade quando cultivada em diferentes solos, como pode ser observado com as diferenças dos modelos calibrados entre as áreas 1, 2 e 3. Além disso, a instabilidade dos modelos quando validados com dados coletados em diferentes safras (Tabela 3), mostra que, além da diferença entre variedades e áreas, fatores do ambiente podem modificar a resposta espectral da cultura.

A variedade SP 81 3250 foi a única cultivada nas três áreas experimentais, com o objetivo principal de verificar o efeito do ambiente na resposta espectral da cana-de-açúcar. Nesta etapa foi realizada a calibração de modelos de regressão simples para estimativa do TFN, utilizando os resultados do índice BNi na variedade SP 81 3250, combinando dados coletados nas três áreas experimentais na safra 2012/13 e posteriormente validação dos mesmos utilizando dados da safra 2013/14, comparados com os modelos gerados por área individual com a mesma variedade (Figura 10).

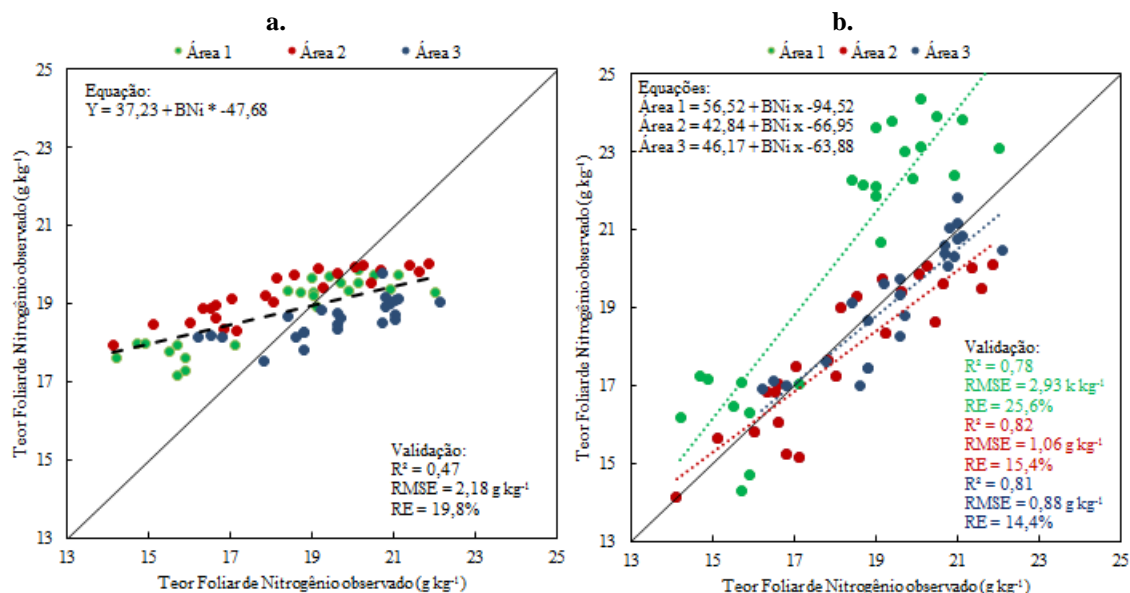


Figura 10 - Análise gráfica do resultado de calibração e validação dos modelos de regressão para a predição do Teor Foliar de Nitrogênio a partir do índice espectral BNi, para a variedade SP 81 3250. (a) Combinação dos dados das três áreas experimentais; (b) Modelos individual por área

O modelo combinado para a variedade SP 81 3250 mostrou resultados significativos na fase de validação, com $R^2 = 0,46$ ($p < 0,01$), $\text{RMSE} = 2,18 \text{ g kg}^{-1}$ e $\text{RE} = 19,8\%$, no entanto quando comparado aos modelos por área individual, o desempenho do modelo mais generalista mostra resultados inferiores, sendo visual a redução da sensibilidade a variação do TFN, uma vez que na fase de validação, os resultados observados em laboratório variaram de 13,8 a 22,7 g kg^{-1} e os estimados pelo modelo de 17 a 20,2 g kg^{-1} (Figura 10a). Os modelos individuais gerados para a área 2 e área 3 mostraram bom desempenho, com R^2 de 0,82 e

0,81, RMSE de 1,06 e 0,88 g.kg⁻¹ e RE de 15,4% e 14,4% respectivamente, com valores próximos a linha 1:1 (Figura 10b).

O modelo individual gerado para a área 1 apesar de apresentar bom R² na fase de validação (0,78) teve valores elevados para RMSE (2,93 g kg⁻¹) e RE (25,6%). A provável causa desta disparidade está relacionada a variações das condições climáticas e umidade do solo. Na safra 2012/13 na época de avaliação todas as áreas se encontravam em condições adequadas de umidade do solo, como pode ser observado no balanço hídrico sequencial da cultura (Figura 4), já na safra 2013/14, ao contrário, todas as áreas encontravam-se sob déficit hídrico.

Apesar disto, a área 2 possui solo argiloso, com maior potencial de armazenamento de água e estava a menos dias sem receber chuvas significativas. Já a área 3 havia recebido precipitações de 9,8 mm nos últimos três dias antes da avaliação, o que não foi suficiente para reduzir a depleção de água no solo, abaixo do nível de água prontamente disponível, mas que amenizou o estado de déficit, por outro lado a área 1, estava a 11 dias sem receber alguma precipitação significativa (Figura 4).

Outro fator importante a frisar é que um dia após a avaliação da área 3 ocorreu foi registrado precipitação de 60 mm, e a mudança das condições atmosféricas já foram observadas no dia da coleta, sendo que para área 3, o saldo de irradiação foi de 24,43 MJ m⁻² d⁻¹, temperatura média de 26,6°C e umidade relativa do ar de 64,3%, enquanto que a área 1, que apresentou maior disparidade na fase de calibração, apresentou saldo de irradiação de 27,33 MJ m⁻² d⁻¹, temperatura média de 29,9°C e umidade relativa do ar média de 47,3%, evidenciando que além da escassez de água no solo, a demanda atmosférica na época de avaliação foi muito elevada nesta área (dados não apresentados).

Do ponto de vista fisiológico, a escassez de água ocasiona alterações significativas na absorção do nutriente pelas culturas (BANDYOPADHYAY et al., 2014), o que explica em partes a razão da maior variância dos dados na safra 2013/14 comparada a 2012/13 para todas as áreas.

Outro fator importante a ser ressaltado é que, variações nas condições de umidade no solo e na planta no momento da coleta das folhas para análise espectral, pode alterar significativamente os resultados das curvas espectrais, tanto na região do infravermelho próximo, devido a alterações na relação água/ar no mesófilo esponjoso, que aumenta a reflectância nesta região do espectro, quanto na região espectral fotossinteticamente ativa (visível e “red-edge”), relacionados a processos de fotoproteção das plantas, que rearranjam suas estruturas fotossinteticamente ativas, visando reduzir a absorção da energia

eletromagnética; processo descrito na literatura como rearranjo dos cloroplastos (ZYGIELBAUM et al., 2012), além de outros processos físicos visando minimizar as trocas gasosas com o ambiente (GRIFFITHS; PARRY, 2002).

Esta análise indica que um modelo utilizando apenas dados de reflectância da folha a partir de sensores não pode responder adequadamente a complexidade das interações entre o organismo vegetal com o ambiente ao longo do espaço e tempo, sendo que uma calibração local utilizando a própria cultura como indicador, como já proposto por Raun et al. (2002), pode ser uma alternativa para mitigar estas limitações. Outra alternativa pode vir de estudos mais aprofundados e modelagens mais complexas que visem combinar dados espectrais, climáticos e edáficos.

4.5 Seleção de variáveis predictoras pelo método sPLS

Os resultados dos coeficientes obtidos pela aplicação da metodologia sPLS, para curvas de reflectância e PDE, são apresentados na Figura 11. Embora na fase calibração tenham sido gerados modelos por área experimental e um modelo geral, na fase de seleção de variáveis pelo método sPLS foi utilizado o conjunto de dados completo para a safra 2012/13 (216 amostras).

Esta ação visou selecionar comprimentos de onda com relação global com as variações do TFN, uma vez que, por mais que uma variedade/ambiente apresente correlações com comprimentos de ondas específicos, do ponto de vista prático é possível o desenvolvimento de um sensor que possua algumas bandas, com algoritmos que permitam migrar entre diferentes combinações destas, já o desenvolvimento de sensores para condições específicas não se mostra viável.




Figura 11 - Resultados para os coeficientes (sPLS), para redução de dimensão e seleção de variáveis para predição do Teor Foliar de Nitrogênio em cana-de-açúcar (Dados da safra 2012/13), para dados de reflectância e Primeira Derivada do Espectro (PDE)

Observa-se que a região do visível e do “*red-edge*” são as mais importantes quando se analisam os resultados dos coeficientes para as curvas de reflectância, sendo o comprimento de onda de 690 nm, o que apresentou maiores valores dos coeficientes sPLS. A região do vermelho e os comprimentos de onda que vão de 840 a 960 nm, apresentaram significância baixa ou quase nula, sendo ainda que a reflectância do comprimentos de onda de 985 nm também mostrou ser uma variável significativa para predição do TFN (Figura 11).

Os coeficientes calculados para os dados da PDE foram de menor amplitude comparados aos calculados para a curva de reflectância. No entanto as regiões espectrais mais importantes se repetem, sendo estas a região do verde, principalmente 525 nm e 565 nm, a região do “*red-edge*” em 680 e 715 nm. Além destas, outras feições em 790, 800, 855 e 980 nm, também mostraram altos valores dos coeficientes sPLS (Figura 11).

Existem poucos trabalhos na literatura que utilizaram a metodologia sPLS para seleção de variáveis em dados hiperespectrais, número ainda mais restrito quando se diz respeito a vegetação e nenhum foi encontrado visando a seleção de variáveis para predição de nitrogênio nas culturas.

Entre as poucas pesquisas encontrados sobre a aplicação do sPLS na vegetação está a pesquisa realizada por Peerbhay et al. (2014), que compararam o método tradicional de mínimos quadrados parciais (PLS) com o sPLS, na seleção de variáveis para análise discriminante de variedades de pinos na África do Sul, onde a eficiência da análise discriminante saltou de 71,88% utilizando PLS, para 80,21% utilizando sPLS, sendo o mesmo observado por Abdel-Rahman et al. (2014) quando compararam as duas metodologias para seleção de variáveis e geração de modelos para predição da produtividade de olerícolas também na África do Sul.

Os maiores valores observados dos coeficientes sPLS, mostraram coerência em relação às regiões do espectro já anteriormente citadas em literatura com relação à sensibilidade a variações no teor de pigmentos na vegetação e ao teor de nitrogênio em nível de folha e dossel (MIPHOKASAP et al., 2012; RAMOELO et al., 2013). A eficiência das melhores variáveis apresentadas na Figura 11 para predição do TFN em cana-de-açúcar poderá ser observada nas análises apresentadas a seguir.

4.6 Calibração de modelos de regressão linear múltipla por “*stepwise*” (SMLR) para predição do teor foliar de nitrogênio em cana-de-açúcar

Na fase de calibração utilizando os dados da safra 2012/13, os resultados obtidos tanto para os modelos gerados com os dados de reflectância quanto os gerados a partir de dados da

PDE, apresentaram desempenho muito parecidos, com valores de R^2 ajustados em torno de 0,70 quando analisadas áreas individuais e 0,60 para o modelo que incorpora todo o conjunto de dados (Tabela 3).

Observa-se que os modelos calibrados por área possuem algumas variações em relação as bandas utilizadas, sendo que foram necessárias de cinco a seis bandas para a calibração do melhor modelo, tanto para os dados de reflectância quando para os dados da PDE. Já os modelos gerais, que incorporam dados das três áreas experimentais, necessitaram de um número maior de bandas, sendo 10 para os dados de reflectância e 9 para os dados da PDE, sugerindo que quanto mais complexo for o conjunto de dados, maior número de variáveis serão necessárias para estabilidade dos modelos e mesmo assim observa-se uma considerável piora nos valores de R^2 ajustado, RMSE e RE.

Tabela 4 - Calibração de modelos de Regressão Linear Múltipla por Stepwise para predição do Teor Foliar Nitrogênio em cana-de-açúcar por área experimental e combinando os dados de todas as áreas para os dados de reflectância e primeira derivada do espectro. Nas equações, a letra B representa o comprimento de onda utilizado no modelo.

Variedade	Equação	$R^2_{aj.}$	RMSE (g kg ⁻¹)	RE (%)
REFLECTÂNCIA	Área 1 $Y = 6,39 - 193,94 * B545 + 402,47 * B655 - 975,19 * B670 + 573,95 * B690 - 141,56 * B745 + 208,32 * B985$	0,71	0,85	4,61
	Área 2 $Y = -8,79 - 179,10 * B515 - 501,78 * B530 + 309,93 * B545 + 334,81 + B690 - 22,59 * B705 + 93,36 * B985$	0,70	0,80	4,44
	Área 3 $Y = 18,7 - 382,57 * B515 + 462,67 * B545 + 577,96 * B655 - 488,44 * B710 + 59,12 * B985$	0,77	1,10	6,13
	Geral $Y = 19,58 - 126,27 * B515 - 226,65 * B530 + 263,24 * B555 + 603,28 * B655 - 917,16 * B670 + 780,43 * B690 - 707,28 * B705 + 288,92 * B710 - 325,38 * B805 + 359,35 * B985$	0,61	1,14	6,32
PDE	Área 1 $Y = 9,41 + 2949,41 * B565 + 5592,59 * B680 + 10824,31 * B755 - 15297,19 * B790 - 5904,62 * B800$	0,72	0,74	4,07
	Área 2 $Y = 11,88 + 6534,97 * B565 + 8502,91 * B680 + 1308,82 * B725 + 14029,82 * B765 - 11480,74 * B790 + 10243,02 * B855$	0,75	0,71	3,91
	Área 3 $Y = 18,98 + 2625,68 * B565 + 14071,61 * B755 - 6721,05 * B790 + 10373,55 * B855 + 3748,25 * B950$	0,72	1,14	6,28
	Geral $Y = 11,69 + 2684,89 * B565 + 1632,10 * B680 + 1061,56 * B725 + 4173,27 * B755 + 5571,42 * B765 - 3524,83 * B790 - 7174,49 * B800 + 7956,21 * B855 + 2098,74 * B950$	0,61	1,21	6,65

Observou-se que os comprimentos de onda mais sensíveis a variação no nitrogênio se encontram na região do verde e do “red-edge”, sendo estas bastante citadas na literatura

como sensíveis a alterações na concentração de pigmentos na folha, sendo a clorofila, a mais abundante em plantas verdes (XUE; YANG, 2009).

Folhas saudáveis apresentam uma feição de reflectância típica na região espectral do verde (490 a 580 nm), uma vez que a luz verde é absorvida em menores quantidades quando comparadas com a luz azul e vermelha, sendo a luz verde predominante em relação à energia refletida e transmitida para esta faixa do espectro. No entanto, a absorção na região do verde, ainda assim é significativa, e aumenta com o incremento da concentração de clorofila na folha, que por sua vez é diretamente sensível a captação de nitrogênio pela planta (TERASHIMA et al., 2009). Neste sentido, plantas estressadas tendem a apresentar folhas com tonalidade verde clara a amarelada, enquanto que plantas bem nutridas, tendem a apresentar folhas com tonalidades verde escuras. A concentração de outros pigmentos como carotenoides, xantofilas e antocianinas também ocasionam variações no comportamento espectral da região do visível.

A região espectral do “*red-edge*”, se refere à região do espectro eletromagnético de rápida modificação na reflectância, na interface entre os comprimentos de onda do visível e do infravermelho próximo. Esta região do espectro, tem sido citada constantemente como sensíveis a variação de pigmentos em plantas, especialmente a clorofila, existindo um número expressivo de estudos voltados exclusivamente a utilização de informações desta região no monitoramento da eficiência fotossintética da vegetação e o estado nutricional de nitrogênio (CHO; SKIDMORE, 2006).

A validação dos modelos gerados por área e com a combinação dos dados de todas as áreas para os dados de reflectância e PDE, foi realizada utilizando dados independentes coletados na safra 2013/14 (Figura 12). Os modelos espectrais por áreas individuais mostraram desempenho satisfatórios, principalmente para as áreas 2 e 3. Na área 2, os valores de R^2 ajustado, RMSE e RE foram de respectivamente 0,72, 1,39 g kg⁻¹ e 7,49% para os dados de reflectância e 0,73, 1,29 g kg⁻¹ e 7,26% para os dados de PDE. Esses resultados são compatíveis inclusive com os observados por Miphokasap et al. (2012) estudando a cultura da cana-de-açúcar na Tailândia, um dos únicos trabalhos empregando dados hiperespectrais para monitoramento do nitrogênio na cultura.

Os modelos gerais, tanto para os dados de reflectância quanto aos de PDE, mostraram redução significativa na precisão da estimativa quando comparados aos resultados observados na fase de calibração, com valores de R^2 ajustado, RMSE e RE respectivamente de 0,51, 1,58 g kg⁻¹ e 9,20% para os dados de reflectância e 0,52, 1,48 g kg⁻¹ e 8,81% para os dados de PDE (Figura 12).

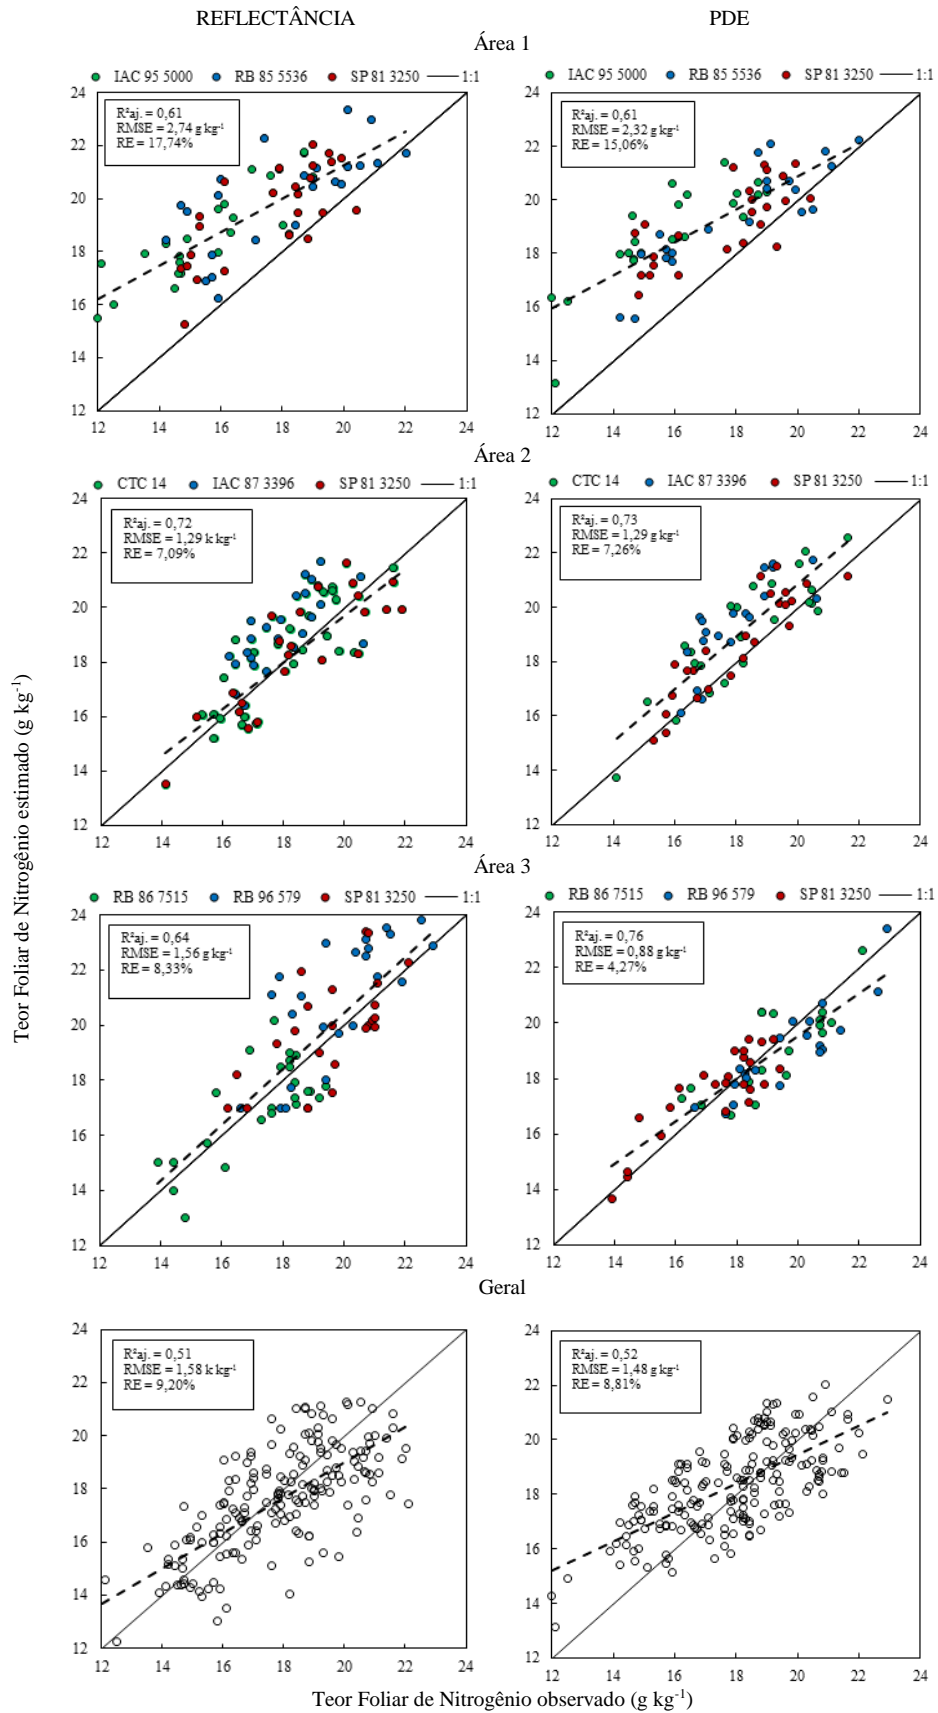


Figura 12 - Resultados da fase de validação dos modelos de Regressão Múltipla por Stepwise para estimativa do teor foliar de nitrogênio em cana-de-açúcar utilizando dados de Reflectância e Primeira Derivada do Espectro eletromagnético (PDE)

O modelo individual gerado para a área 1, apesar de apresentar bom R^2 ajustado na fase de validação (0,61 tanto para reflectância quanto para a PDE) teve valores elevados para RMSE e RE, com $2,74 \text{ g kg}^{-1}$ e 17,74% para os modelos de reflectância e $2,32 \text{ g kg}^{-1}$ e 15,06% para os modelos de PDE (Figura 12). Grande parte desta disparidade se deve principalmente as variações das condições climáticas e da umidade do solo já citadas anteriormente.

Os resultados apresentados encontram-se coerentes com outros estudos utilizando sensores hiperespectrais para outras culturas ou regiões produtores ao redor do mundo, entres os quais pode-se citar a cultura do trigo (CAMMARANO et al., 2014), arroz (TIAN et al., 2011), milho (QUEMADA; GABRIEL; ZARCO-TEJADA, 2014) ou mesmo cana-de-açúcar (MIPHOKASAP et al., 2012).

Algumas pesquisas já desenvolvidas no Brasil utilizando sensores ópticos comerciais em nível de dossel para cultura da cana-de-açúcar, observaram limitações em relação a calibração de um algoritmo eficiente para estimativa do estado nutricional de nitrogênio, sendo os resultados variáveis entre áreas produtivas e variedades ou até mesmo em estabelecer faixas de resposta do sensor que estejam relacionadas a perdas de produtividade ou eficiência do uso destes fertilizantes (AMARAL; MOLIN; SCHEPERS, 2015; ROSA et al., 2015).

Observou-se a existência de potencial para o uso de informações da reflectância no monitoramento da variação do nitrogênio em cana-de-açúcar que ocorrem em faixas específicas do espectro, com destaque a comprimentos de onda do verde e do “*red-edge*”; embora estudos em folhas não representam diretamente o que acontece em nível de dossel ou mesmo orbital, e sendo assim, futuras investigações se fazem necessários para corroborar com estas informações.

Os modelos espectrais da folha de cana-de-açúcar podem ser aplicados para predição do teor foliar de nitrogênio, com potencial de substituição das análises químicas de tecidos vegetais convencionais, tendo a vantagem de ser um método limpo e de baixo custo. Além disso, este estudo de base visa ser norteador de futuras pesquisas nesta área, que visem o aprofundamento e consolidação desta tecnologia.

5 CONCLUSÕES

Com base nos resultados apresentados é possível concluir que os dados hiperespectrais, mesmo das folhas da cana-de-açúcar, sofrem forte influência de diversos fatores, onde ressalta-se a influência do ambiente de cultivo, a variação genética entre os cultivares e variabilidade temporal de fatores climáticos. Apesar disso é possível observar regiões espectrais fortemente influenciadas pelas variações do teor foliar de nitrogênio, sendo estas as regiões da luz verde, e a região de forte inflexão da reflectância, na borda que divide os comprimentos de onda do vermelho e infravermelho próximo denominada na literatura como “*red-edge*”.

Os índices de vegetação comumente citados em literatura como sensíveis as alterações das estruturas fotossinteticamente ativa nos vegetais, podem ser utilizados para predição do teor foliar de nitrogênio, no entanto modelos deverão ser ajustados por variedade e áreas individuais. Este problema pode ser parcialmente contornado utilizando combinações lineares por meio de regressão linear múltipla por “*stepwise*”, que neste caso melhorou a estabilidade, fazendo com que modelos mais generalistas pudessem ser calibrados.

Independentemente das limitações apresentadas nesta pesquisa, a resposta espectral da cana-de-açúcar se mostra uma boa ferramenta para o monitoramento da variabilidade do status de nitrogênio na cultura, podendo vir a substituir as análises de rotina para este nutriente, como método sustentável de análise de tecido foliar, além de contribuir à futuras pesquisas que visem desenvolver modelos espectrais de dossel, aéreo ou orbital para detecção da variabilidade espacial do teor e captação deste nutriente pela cultura da cana-de-açúcar.

REFERÊNCIAS

- ABDEL-RAHMAN, E.M.; AHMED, F.B.; VAN DEN BERG, M.; WAY, M.J. Potential of spectroscopic data sets for sugarcane thrips (*Fulmekiola serrata* Kobus) damage detection. **International Journal of Remote Sensing**, Oxford, v. 31, n. 15, p. 4199–4216, 2010.
- ABDEL-RAHMAN, E.M.; MUTANGA, O.; ODINDI, J.; ADAM, E.; ODINDO, A.; ISMAIL, R. A comparison of partial least squares (PLS) and sparse PLS regressions for predicting yield of Swiss chard grown under different irrigation water sources using hyperspectral data. **Computers and Electronics in Agriculture**, Amsterdam, v. 106, p. 11–19, 2014.
- ALLEN, R.G.; PEREIRA, L.S.; RAES, K.; SMITH, M. **Crop evapotranspiration: guidelines for computing crop water requirements**. Rome: FAO, 1998. 300 p. (FAO. Irrigation and Drainage Paper, 56).
- AMARAL, L.R.; MOLIN, J.P.; PORTZ, G.; FINAZZI, F.B.; CORTINOVE, L. Comparison of crop canopy reflectance sensors used to identify sugarcane biomass and nitrogen status. **Precision Agriculture**, Amsterdam, v. 16, n. 1, p. 15–28, 2014.
- AMARAL, L. R.; MOLIN, J. P.; SCHEPERS, J. S. Algorithm for variable-rate nitrogen application in sugarcane based on active crop canopy sensor. **Agronomy Journal**, Madison v. 107, n. 4, p. 1513–1523, 2015.
- APARICIO, N.; VILLEGAS, D.; CASADESUS, J.; ARAUS, J.L.; ROYO, C. Spectral vegetation indices as nondestructive tools for determining durum Wheat yield. **Agronomy Journal**, Madison, v. 92, n. 1, p. 83–91, 2000.
- BANDYOPADHYAY, K.K.; PRADHAN, S.; SAHOO, R.N.; SINGH, R.; GUPTA, V.K.; JOSHI, D.K.; SUTRADHAR, A.K. Characterization of water stress and prediction of yield of wheat using spectral indices under varied water and nitrogen management practices. **Agricultural Water Management**, Amsterdam, v. 146, p. 115–123, 2014.
- BEGUE, A.; LEBOURGEOIS, V.; BAPPEL, E.; TODOROFF, P.; PELLEGRINO, A.; BAILLARIN, F.; SIEGMUND, B. Spatio-temporal variability of sugarcane fields and recommendations for yield forecast using NDVI. **International Journal of Remote Sensing**, Oxford, v. 21, p. 5391–5407, 2010.
- BEN-DOR, E.; ONG, C.; LAU, L. C. Reflectance measurements of soils in the laboratory: standards and protocols reference. **Geoderma**, Amsteran, v. 245, p. 112-124, 2015.
- BIEWER, S.; FRICKE, T.; WACHENDORF, M. Development of canopy reflectance models to predict forage quality of legume-grass mixtures. **Crop Science**, Madison, v. 49, n. 5, p. 1917–1926, 2009.
- BIRTH, G.S.; MCVEY, G.R. Measuring the colour of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, Madison, v. 60, p. 640–643, 1968.
- BLACKBURN, G.A. Quantifying chlorophylls and carotenoids at leaf and canopy scales. **Remote Sensing of Environment**, Amsterdam, v. 66, n. 3, p. 273–285, 1998.

BOLOGNA-CAMPBELL, I.R. **Balço de nitrogênio e enxofre no sistema solo-cana-de-açúcar no ciclo de cana-planta**. 2007. 110 p. Tese (Doutorado em Solos e Nutrição de Plantas) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2007.

CAMMARANO, D.; FITZGERALD, G.; CASA, R.; BASSO, B. Assessing the robustness of vegetation index to estimate wheat N in Mediterranean environments. **Remote Sensing**, Basel, v. 6, p. 2827–2844, 2014.

CANTARELLA, H.; TRIVELIN, P.C.O.; VITTI, A. C. Nitrogênio e enxofre na cultura da cana-de-açúcar. In: YAMADA, T.; ABDALLA, S.R.S.; VITTI, G.C. (Ed.). **Nitrogênio e enxofre na agricultura brasileira**. Piracicaba: IPNI Brasil, 2007. p. 355–412.

CASAGRANDE, A.A. **Tópicos de morfologia e fisiologia da cana-de-açúcar**. Jaboticabal: FUNEP, 1991. 157p.

CECCATO, P.; FLASSE, S.; TARANTOLA, S.; JACQUEMOUD, S.; GRÉGOIRE, J. M. Detecting vegetation leaf water content using reflectance in the optical domain. **Remote Sensing of Environment**, Amsterdam, v. 77, p. 22–33, 2001.

CHO, M.A.; SKIDMORE, A.K. A new technique for extracting the red edge position from hyperspectral data: the linear extrapolation method. **Remote Sensing of Environment**, Amsterdam, v. 101, n. 2, p. 181–193, 2006.

CHUN, H.; KELEŞ, S. Sparse partial least squares regression for simultaneous dimension reduction and variable selection. **Journal of the Royal Statistical Society. Series B: Statistical Methodology**, New York, v. 72, n. 1, p. 3–25, 2010.

CHUNG, D.; CHUN, H. **An introduction to the "spls" Package, Version 1.0**. 2012. Disponível em: <<http://cran.r-project.org/web/packages/spls/vignettes/spls-example.pdf>>. Acesso em: 26 nov. 2015.

CONN, E.E.; STUMPF, P.K.; BRUENING, G.; DOI, R.H. **Outlines of biochemistry**. New York: John Wiley, 1987. 693 p.

CURRAN, P.J. Remote sensing of foliar chemistry. **Remote Sensing of Environment**, Amsterdam, v. 30, p. 271–278, 1989.

DARVISHZADEH, R. ; SKIDMORE, A.; SCHLERF, M.; ATZBERGER, C.; CORSI, F.; CHO, M. LAI and chlorophyll estimation for a heterogeneous grassland using hyperspectral measurements. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 63, n. 4, p. 409–426, 2008.

DASH, J.; CURRAN, P. J. The MERIS terrestrial chlorophyll index. **International Journal of Remote Sensing**, Oxford, v. 25, n. 23, p. 5403–5413, 2004.

DORIGO, W.A.; ZURITA-MILLA, R.; DE WIT, A.J.W.; BRAZILE, J.; SINGH, R.; SCHAEPMAN, M.E. A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. **International Journal of Applied Earth Observation and Geoinformation**, Amsterdam, v. 9, n. 2, p. 165–193, 2007.

ERDLE, K.; MISTELE, B.; SCHMIDHALTER, U. Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. **Field Crops Research**, Amsterdam, v. 124, n. 1, p. 74–84, 2011.

ESTES, L.D.; OKIN, G.S.; MWANGI, A.G.; SHUGART, H.H. Habitat selection by a rare forest antelope: a multi-scale approach combining field data and imagery from three sensors. **Remote Sensing of Environment**, Amsterdam, v. 112, p. 2033–2050, 2008.

FERWERDA, J.G.; SKIDMORE, A.K. Can nutrient status of four woody plant species be predicted using field spectrometry? **ISPRS Journal of Photogrammetry & Remote Sensing**, Amsterdam, v. 62, p. 406–414, 2007.

FIGUEIREDO, P. Breve história da cana-de-açúcar e do papel do Instituto Agrônômico no seu estabelecimento no Brasil. In: DINARDO-MIRANDA, L.L.; VASCONCELOS, A.C.M.; LANDELL, M.G.A. (Ed.). **Cana-de-açúcar**. Campinas: Instituto Agrônômico, 2008. p. 31-44.

FRANCO, H. C. J.; OTTO, R.; FARONI, C. E.; VITTI, A. C.; ALMEIDA DE OLIVEIRA, E. C.; TRIVELIN, P. C. O. Nitrogen in sugarcane derived from fertilizer under Brazilian field conditions. **Field Crops Research**, Amsterdam, v. 121, n. 1, p. 29–41, 2011.

FRANCO, H. C. J.; OTTO, R.; VITTI, A. C.; FARONI, C. E.; ALMEIDA, E. C. De; FORTES, C.; FERREIRA, D. A.; KÖLLN, O. T.; GARSIDE, A. L.; CESAR, P.; TRIVELIN, O. Residual recovery and yield performance of nitrogen fertilizer applied at sugarcane planting. **Scientia Agricola**, Piracicaba, v. 72, n. 6, p. 528–534, 2015.

FRANCO, H. C. J.; TRIVELIN, P. C. O.; FARONI, C. E.; VITTI, A. C.; OTTO, R. Stalk yield and technological attributes of planted cane as related to nitrogen fertilization. **Scientia Agricola**, Piracicaba v. 67, p. 579–590, 2010.

GITELSON, A.; MERZLYAK, M.N. Quantitative estimation of chlorophyll-a using reflectance spectra: experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology B: Biology**, Amsterdam, v. 22, n. 3, p. 247–252, 1994.

GRIFFITHS, H.; PARRY, M.A.J. Plant responses to water stress. **Annals of Botany**, Oxford, v. 89, n. 7, p. 801–802, 2002.

GUPTA, R.K.; VIJAYAN, D.; PRASAD, T.S. Comparative analysis of red edge hyperspectral indices. **Advances in Space Research**, Amsterdam, v. 32, p. 2217–2222, 2003.

HERRMANN, I.; PIMSTEIN, a; KARNIELI, a; COHEN, Y.; ALCHANATIS, V.; BONFIL, D. J. LAI assessment of wheat and potato crops by VEN μ S and Sentinel-2 bands. **Remote Sensing of Environment**, Amsterdam, v. 115, n. 8, p. 2141–2151, 2011.

JENSEN, J.R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestre**. 2. ed. São José dos Campos: Parêntese, 2009. 672 p.

KNIPLING, E.B. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. **Remote Sensing of Environment**, Amsterdam, v. 1, n. 3, p. 155–159, 1970.

KNOX, N.M.; SKIDMORE, A.K.; PRINS, H.H.T.; ASNER, G.P.; VAN DER WERFF, H.M.; DE BOER, W.F.; VAN DER WAAL, C.; DE KNEGT, H.J.; KOHI, E.M.; SLOTOW, R.; GRANT, R.C. Dry season mapping of savanna forage quality, using the hyperspectral Carnegie Airborne Observatory sensor. **Remote Sensing of Environment**, Amsterdam, v. 115, n. 6, p. 1478–1488, 2011.

KORNDÖRFER, G.H.; PEREIRA, H.S.; CAMARGO, M.S. **Silicato de cálcio e magnésio na agricultura**. Uberlândia: UFU; ICIAG, 2002. 24 p. (GPSi-ICIAG-UFU. Boletim Técnico, 1).

LEBOURGEOIS, V.; BÉGUÉ, A.; LABBÉ, S.; HOULÈS, M.; MARTINÉ, J.F. A light-weight multi-spectral aerial imaging system for nitrogen crop monitoring. **Precision Agriculture**, Amsterdam, v. 13, n. 5, p. 525–541, 2012.

LI, F.; MIAO, Y.; HENNIG, S.D.; GNYP, M.L.; CHEN, X.; JIA, L.; BARETH, G. Evaluating hyperspectral vegetation indices for estimating nitrogen concentration of winter wheat at different growth stages. **Precision Agriculture**, Amsterdam, v. 11, n. 4, p. 335–357, 2010.

MAHAJAN, G.R.; SAHOO, R.N.; PANDEY, R.N.; GUPTA, V.K.; KUMAR, D. Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur and potassium in wheat (*Triticum aestivum* L.). **Precision Agriculture**, Amsterdam, v. 15, p. 499–522, 2014.

MALAVOLTA, E.; VITTI, G.C.; OLIVEIRA, S.A. **Avaliação do estado nutricional das plantas: princípios e aplicações**. 2. ed. Piracicaba: POTAFOS, 1997. 319 p.

MARSHAK, A.; KNYAZIKHIN, Y.; DAVIS, A.B.; WISCOMBE, W.J.; PILEWSKIE, P. Cloud-vegetation interaction: use of normalized difference cloud index for estimation of cloud optical thickness. **Geophysical Research Letters**, New York, v. 27, n. 12, p. 1695–1698, 2000.

MARTENS, H.; NAES, T. **Multivariate calibration**. Chichester: John Wiley, 1989. 419 p.

MENGEL, K.; KIRKBY, E.A. **Principles of plant nutrition**. Bern: International Potash Institute, 1987. 687 p.

MIAO, Y.; MULLA, D.J.; RANDALL, G.W.; VETSCH, J.A.; VINTILA, R. Combining chlorophyll meter readings and high spatial resolution remote sensing images for in-season site-specific nitrogen management of corn. **Precision Agriculture**, Amsterdam, v. 10, n. 1, p. 45–62, 2009.

MIPHOKASAP, P.; HONDA, K.; VAIPHASA, C.; SOURIS, M.; NAGAI, M. Estimating canopy nitrogen concentration in sugarcane using field imaging spectroscopy. **Remote Sensing**, Basel, v. 4, n. 12, p. 1651–1670, 2012.

MOLIN, J.P. Use of active optical sensors for crops in Brazil. **Better Crops**, Peachtree Corners, v. 94, p. 18–20, 2010.

MOREIRA, M.A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4. ed. Viçosa: UFV, 2011. 422 p.

MULLA, D.J. Twenty five years of remote sensing in precision agriculture: key advances and remaining knowledge gaps. **Biosystems Engineering**, Amsterdam, v. 114, n. 4, p. 358–371, 2013.

NIGON, T.J.; MULLAA, D.J.; ROSENA, C.J.; COHENB, Y.; ALCHANATISB, V.; KNIGHTC, J.; RUDB, R. Hyperspectral aerial imagery for detecting nitrogen stress in two potato cultivars. **Computers and Electronics in Agriculture**, Amsterdam, v. 112, p. 36–46, 2015.

OTTO, R.; COUTINHO, H.; FRANCO, J.; FARONI, C. E.; VITTI, A. C.; CANTIDIO, E.; OLIVEIRA, A.; SERMARINI, R. A.; CESAR, P.; TRIVELIN, O. The role of nitrogen fertilizers in sugarcane root biomass under field conditions. **Agricultural Sciences**, Wuhan, v. 5, p. 1527–1538, 2014.

PEERBHAY, K.Y.; MUTANGA, O.; ISMAIL, R. Does simultaneous variable selection and dimension reduction improve the classification of Pinus forest species? **Journal of Applied Remote Sensing**, Bellingham, v. 8, n. 1, p. 85194-85194, 2014.

PONZONI, F.J.; SHIMABUKURO, Y.E.; KUPLICH, T.M. **Sensoriamento remoto da vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012. 176p.

PRADHAN, S.; BANDYOPADHYAY, K.K.; SAHOO, R.N.; SEHGAL, V.K.; SINGH, R.; GUPTA, V.K.; JOSHI, D.K. Predicting wheat grain and biomass yield using canopy reflectance of booting stage. **Journal of the Indian Society of Remote Sensing**, Berlin, v. 42, n. 4, p. 711–718, 2014.

QUEMADA, M.; GABRIEL, J.; ZARCO-TEJADA, P. Airborne hyperspectral images and ground-level optical sensors as assessment tools for maize nitrogen fertilization. **Remote Sensing**, Basel, v. 6, n. 4, p. 2940–2962, 2014.

RAIJ, B. van; CANTARELLA, H.; QUAGGIO, J.A. FURLANI, A.M.C. **Recomendações de adubação e calagem para o estado de São Paulo**. 2. ed. Campinas: Instituto Agrônomo; Fundação IAC, 1997. 285 p. (Boletim Técnico, 100).

RAMIREZ, G.M.; ZULLO JUNIOR, J. Estimativa de parâmetros biofísicos de plantios de café a partir de imagens orbitais de alta resolução espacial. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 3, p. 468–479, 2010.

RAMOELO, A.; SKIDMORE, A.K.; CHO, M.A.; MATHIEU, R.; HEITKÖNIG, I.M.A.; DUDENI-TLHONE, N.; SCHLERF, M.; PRINS, H.H.T. Non-linear partial least square regression increases the estimation accuracy of grass nitrogen and phosphorus using in situ hyperspectral and environmental data. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 82, p. 27–40, 2013.

RANJAN, R.; CHOPRA, U.K.; SAHOO, R.N.; SINGH, A.K.; PRADHAN, S. Assessment of plant nitrogen stress in wheat (*Triticum aestivum* L.) through hyperspectral indices. **International Journal of Remote Sensing**, Oxford, v. 33, n. 20, p. 6342–6360, 2012.

RAUN, W.R.; SOLIE, J.B.; JOHNSON, G.V.; STONE, M.L.; LUKINA, E.V.; THOMASON, W.E.; SCHEPERS, J.S. In-season prediction of potential grain yield in winter wheat using canopy reflectance. **Agronomy Journal**, Madison, v. 93, p. 131–138, 2001.

RAUN, W.R.; SOLIE, J.B.; JOHNSON, G.V.; STONE, M.L.; MULLEN, R.W.; FREEMAN, K.W.; THOMASON, W.E.; LUKINA, E.V. Improving nitrogen use efficiency in cereal grain production with optical sensing and variable rate application. **Agronomy Journal**, Madison, v. 94, n. 4, p. 815–820, 2002.

REDDY, K.R.; MATCHA, S.K. Remote sensing algorithms for castor bean nitrogen and pigment assessment for fertility management. **Industrial Crops and Products**, Amsterdam, v. 32, n. 3, p. 411–419, 2010.

RODRIGUEZ, D.; FITZGERALD, G.J.; BELFORD, R.; CHRISTENSEN, L.K. Detection of nitrogen deficiency in wheat from spectral reflectance indices and basic crop eco-physiological concepts. **Australian Journal of Agricultural Research**, Melbourne, v. 57, n. 7, p. 781, 2006.

ROSA, H. J. A.; DO AMARAL, L. R.; MOLIN, J. P.; CANTARELLA, H. Sugarcane response to nitrogen rates, measured by a canopy reflectance sensor. **Pesquisa Agropecuária Brasileira**, Brasília, v. 50, n. 9, p. 840–848, 2015.

RYU, C.; SUGURI, M.; UMEDA, M. Model for predicting the nitrogen content of rice at panicle initiation stage using data from airborne hyperspectral remote sensing. **Biosystems Engineering**, Amsterdam, v. 104, n. 4, p. 465–475, 2009.

SANTOS, E. F. dos; DONHA, R. M. A.; MAGNO, C. M.; ARAÚJO, D.; JUNIOR, J. L.; CAMACHO, M. A. Faixas normais de nutrientes em cana-de-açúcar pelos métodos ChM, DRIS, CND e nível crítico pela distribuição normal reduzida. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 37, n. 6, p. 1651–1658, 2013.

SEGATO, S.V.; PINTO, A.S.; JENDIROBA, E.; NÓBREGA, J.C.M. **Atualização em produção de cana-de-açúcar**. Piracicaba: Livroceres, 2006. 415 p.

SHAVER, T.M.; KHOSLA, R.; WESTFALL, D.G. Evaluation of two crop canopy sensors for nitrogen variability determination in irrigated maize. **Precision Agriculture**, Amsterdam, v. 12, p. 892–904, 2011.

SILVA, M.A.S. da; GRIEBELER, N.P.; BORGES, L.C. Uso de vinhaça e impactos nas propriedades do solo e lençol freático. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 11, n. 1, p. 108–114, 2007.

SIMS, D.A.; GAMON, J.A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, Amsterdam, v. 81, n. 2, p. 337–354, 2002.

SKIDMORE, A.K.; FERWERDA, J.G.; MUTANGA, O.; VAN WIEREN, S.E.; PEEL, M.; GRANT, R.C.; PRINS, H.H.T.; BALCIK, F.B.; VENUS, V. Forage quality of savannas: simultaneously mapping foliar protein and polyphenols for trees and grass using hyperspectral imagery. **Remote Sensing of Environment**, Amsterdam, v. 114, n. 1, p. 64–72, 2010.

SOLARI, F.; SHANAHAN, J.; FERGUSON, R.; SCHEPERS, J.; GITELSON, A. Active sensor reflectance measurements of corn nitrogen status and yield potential. **Agronomy Journal**, Madison, v. 100, n. 3, p. 571–579, 2008.

STEFFEN, C. A.; MORAES, E. C.; GAMA, F. F. Radiometria óptica espectral. In: VIII Simpósio Brasileiro de Sensoriamento Remoto, Salvador. Anais... Salvador: 1996.

STEFFEN, C.A.; MORAES, E.C.; GAMA, F.F. Radiometria óptica espectral. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. **Anais...** São José dos Campos: INPE, 1996. p. 14-19.

TERASHIMA, I.; FUJITA, T.; INOUE, T.; CHOW, W.S.; OGUCHI, R. Green light drives leaf photosynthesis more efficiently than red light in strong white light: revisiting the enigmatic question of why leaves are green. **Plant & Cell Physiology**, Oxford, v. 50, n. 4, p. 684–97, 2009.

THORBURN, P. J.; MEIER, E. A.; PROBERT, M. E. The fate of nitrogen applied to sugarcane by trickle irrigation. **Irrigation Science**, Madson, v. 22, p. 201–209, 2003.

TIAN, Y.; YAO, X.; YANG, J.; CAO, W.; ZHU, Y. Extracting red edge position parameters from ground and space-based hyperspectral data for estimation of canopy leaf nitrogen concentration in rice. **Plant Production Sciences**, Tokyo, v. 14, p. 270–281, 2011.

UNICA - UNIÃO DA INDÚSTRIA DE CANA-DE-AÇÚCAR. Disponível em: <<http://www.unica.com.br/>>. Acesso em: 01 mar. 2016.

VIGNEAU, N.; ECARNOT, M.; RABATEL, G.; ROUMET, P. Potential of field hyperspectral imaging as a non destructive method to assess leaf nitrogen content in Wheat. **Field Crops Research**, Amsterdam, v. 122, n. 1, p. 25–31, 2011.

VITTI, A.C.; TRIVELIN, P.C.O.; GAVA, G.J.C.; FRANCO, H.C.J.; BOLOGNA, I.R.; FARONI, C.E. Produtividade da cana-de-açúcar relacionada à localização de adubos nitrogenados aplicados sobre os resíduos culturais em canavial sem queima. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 31, p. 491–498, 2007.

VOGELMANN, J.E.; ROCK, B.N.; MOSS, D.M. Red-edge spectral measurements from sugar maple leaves. **International Journal of Remote Sensing**, Oxford, v. 14, p. 1563–1575, 1993.

WANG, Q.; LI, P. Identification of robust hyperspectral indices on forest leaf water content using PROSPECT simulated dataset and field reflectance measurements. **Hydrological Processes**, Hoboken, v. 26, n. 8, p. 1230–1241, 2012.

XUE, L.; YANG, L. Deriving leaf chlorophyll content of green-leafy vegetables from hyperspectral reflectance. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 64, n. 1, p. 97–106, 2009.

YAO, X.; YAO, X.; JIA, W.; TIAN, Y.; NI, J.; CAO, W.; ZHU, Y. Comparison and intercalibration of vegetation indices from different sensors for monitoring above-ground plant nitrogen uptake in winter wheat. **Sensors**, Basel, v. 13, p. 3109–3130, 2013.

YI, Q.; HUANG, J.; WANG, F.; X., W. Evaluating the performance of PC-ANN for the estimation of rice nitrogen concentration from canopy hyperspectral reflectance. **International Journal of Remote Sensing**, Oxford, v. 32, p. 931–940, 2012.

ZHAO, D.L.; REDDY, K.R.; KAKANI, V.G.; READ, J.J.; KOTI, S. Canopy reflectance in cotton for growth assessment and lint yield prediction. **European Journal of Agronomy**, Amsterdam, v. 26, p. 335–344, 2007.

ZYGIELBAUM, A.I.; ARKEBAUER, T.J.; WALTER-SHEA, E.A.; SCOBY, D.L. Detection and measurement of vegetation photo protection stress response using PAR reflectance. **Israel Journal of Plant Sciences**, Oxford, v. 60, p. 37–47, 2012.

ZYGIELBAUM, A.I.; GITELSON, A.A.; ARKEBAUER, T.J.; RUNDQUIST, D.C. Non-destructive detection of water stress and estimation of relative water content in maize. **Geophysical Research Letters**, New York, v. 36, n. 12, p. 1-4, 2009.

ANEXOS

ANEXO A. Resultados dos coeficientes de determinação (R^2) para todos os índices espectrais avaliados nesta pesquisa na fase de calibração (Safrá 2012/13).

Índice	Área 1			Área 2				Área 3			GERAL		
	IAC955000	RB855536	SP813250	Área	CTC14	IAC873396	SP813250	Área	RB93579	RB867515	SP813250	Área	
	R^2												
BNi	0,92	0,84	0,76	0,51	0,81	0,89	0,72	0,31	0,72	0,88	0,86	0,35	0,10
GMi1	0,73	0,73	0,79	0,48	0,80	0,82	0,82	0,29	0,82	0,82	0,68	0,31	0,08
GMi2	0,69	0,71	0,68	0,37	0,81	0,82	0,83	0,30	0,82	0,83	0,69	0,40	0,07
GNDVI	0,88	0,84	0,79	0,50	0,81	0,89	0,74	0,31	0,77	0,82	0,86	0,34	0,10
mND705	0,76	0,71	0,69	0,33	0,82	0,81	0,82	0,28	0,82	0,86	0,68	0,45	0,07
MTCI	0,69	0,70	0,67	0,35	0,82	0,82	0,84	0,33	0,83	0,83	0,68	0,36	0,05
NDCI	0,72	0,72	0,72	0,41	0,77	0,78	0,81	0,28	0,83	0,82	0,68	0,30	0,06
NDRE	0,88	0,81	0,71	0,39	0,79	0,85	0,77	0,39	0,79	0,87	0,89	0,44	0,06
PSNDa	0,09	0,39	0,33	0,11	0,17	0,33	0,72	0,10	0,66	0,33	0,41	0,11	0,00
PSNDb	0,43	0,55	0,54	0,25	0,51	0,68	0,74	0,17	0,79	0,72	0,55	0,21	0,02
PSNDc	0,36	0,50	0,50	0,23	0,35	0,51	0,75	0,18	0,67	0,60	0,52	0,14	0,03
RI-1Db	0,88	0,80	0,69	0,39	0,82	0,86	0,74	0,36	0,78	0,86	0,88	0,41	0,05
RI-2Db	0,74	0,72	0,67	0,36	0,84	0,81	0,83	0,32	0,83	0,86	0,71	0,40	0,07
RI-3Db	0,74	0,75	0,70	0,39	0,82	0,81	0,84	0,35	0,84	0,85	0,70	0,40	0,05
RI-half	0,69	0,70	0,76	0,40	0,83	0,83	0,84	0,32	0,83	0,84	0,68	0,37	0,06
RNDVI	0,10	0,42	0,35	0,13	0,20	0,45	0,64	0,11	0,67	0,49	0,34	0,10	0,01
SR ₇₀₅	0,68	0,70	0,67	0,35	0,82	0,82	0,83	0,30	0,83	0,84	0,67	0,36	0,05
VOGa	0,88	0,80	0,71	0,38	0,82	0,87	0,75	0,37	0,77	0,86	0,89	0,41	0,04
VOGb	0,62	0,68	0,70	0,28	0,82	0,82	0,85	0,27	0,87	0,82	0,62	0,36	0,06
VOGc	0,69	0,71	0,70	0,33	0,83	0,82	0,85	0,32	0,85	0,84	0,66	0,39	0,05