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

**Espectroscopia de reflectância *in situ* na avaliação da resposta da
adubação nitrogenada na cana-de-açúcar**

Tiago Rodrigues Tavares

Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração:
Engenharia de Sistemas Agrícolas

**Piracicaba
2017**

Tiago Rodrigues Tavares
Engenheiro Agrônomo

Espectroscopia de reflectância *in situ* na avaliação da resposta da adubação nitrogenada na cana-de-açúcar

versão revisada de acordo com a resolução CoPGr 6018 de 2011

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

Dissertação apresentada para obtenção do título de Mestre em Ciências. Área de concentração: Engenharia de Sistemas Agrícolas

Piracicaba
2017

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

Tavares, Tiago Rodrigues

Espectroscopia de reflectância in situ na avaliação da resposta da adubação nitrogenada na cana-de-açúcar/ Tiago Rodrigues Tavares. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - - Piracicaba, 2017.

87p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura "Luiz de Queiroz".

1. Sensoriamento 2. VisNIR 3. Teor Foliar de Nitrogênio 4. Índices de Vegetação I. Título

AGRADECIMENTOS

A meu orientador, professor Peterson Ricardo Fiorio, pela amizade e confiança durante os meus anos de mestrado e também pelo apoio dado, essencial para o meu desenvolvimento pessoal e acadêmico.

Aos professores com quem eu tive contato durante o curso, que gentilmente compartilharam os seus conhecimentos, permitindo o amadurecimento teórico necessário à escrita desta dissertação.

À Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo, que por meio do Programa de Pós-Graduação em Engenharia de Sistemas Agrícolas, pela possibilidade de realização de meu curso de mestrado.

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

Aos pesquisadores Heitor Cantarella e Zaqueu Fernando Montezano, e à equipe de pesquisa do Instituto Agrônomo de Campinas, que possibilitaram o desenvolvimento deste trabalho, junto às áreas experimentais referentes ao projeto temático BIOEN/FAPESP 2008/56147-1.

Aos funcionários do departamento de Engenharia de Biossistemas, pela cordialidade e suporte.

Aos amigos do TopoGeo, da Casa 1872, do LAP, do GeoCis, do grupo CTM, de Americana, Iracemápolis, Campinas e Goiânia, em especial a Maurício, Taila, Wanderlei e Gisele pelo companheirismo que deixou o caminhar mais leve durante os últimos anos.

Aos amigos Tomás e Magno e ao primo Claudio pelo incentivo dado para o ingresso no curso de mestrado.

Aos amigos e professores Juliano Santana e João Gaspar Farias pelo apoio a minha iniciação científica.

E também a toda minha família, em especial à minha mãe Kênia, exemplo de força, dedicação e coerência, e minha avó Terezinha por seu amor incondicional.

EPÍGRAFE

“Feliz aquele que transfere o que sabe e aprende o que ensina”.

Cora Coralina

SUMÁRIO

RESUMO	6
ABSTRACT	7
1. INTRODUÇÃO	9
2. REVISÃO BIBLIOGRÁFICA.....	13
2.1. SENSORIAMENTO NA AGRICULTURA	13
2.2. CONSIDERAÇÕES SOBRE A ADUBAÇÃO NITROGENADA NA CANA-DE-AÇÚCAR.....	16
2.3. SENSORES ÓPTICOS APLICADOS AO AUXÍLIO DA ADUBAÇÃO DE N NA CANA-DE-AÇÚCAR.....	18
2.4. ANÁLISES DE COMPONENTES PRINCIPAIS PARA AVALIAÇÕES QUALITATIVAS DE CURVAS ESPECTRAIS..	22
2.5. MÉTODOS PARA AVALIAÇÕES QUANTITATIVAS DA REFLECTÂNCIA ESPECTRAL	23
3. MATERIAL E MÉTODOS.....	27
3.1. ÁREA EXPERIMENTAL.....	27
3.2. COLETA DE DADOS.....	27
3.3. ANÁLISE DOS DADOS.....	32
4. RESULTADOS E DISCUSSÃO.....	37
4.1. ANÁLISE EXPLORATÓRIA DOS DADOS DE ALTURA, TFN, PRODUTIVIDADE E REGIÕES ESPECTRAIS	37
4.2. RESPOSTA DA PRODUTIVIDADE, ALTURA, TFN E REGIÕES ESPECTRAIS QUANTO A DOSE DE NITROGÊNIO APLICADA	44
4.3. AVALIAÇÃO QUALITATIVA DOS ESPECTROS POR ANÁLISE DESCRITIVA	49
4.4. AVALIAÇÃO QUALITATIVA DOS ESPECTROS POR ANÁLISE DE COMPONENTES PRINCIPAIS	50
4.5. DETERMINAÇÃO DO TFN POR MEIO DOS DADOS ESPECTRAIS	55
5. CONCLUSÕES	69
6. CONSIDERAÇÕES FINAIS	71
REFERÊNCIAS	73
APÊNDICES.....	81

RESUMO

Espectroscopia de reflectância in situ na avaliação da resposta da adubação nitrogenada na cana-de-açúcar

Na agricultura, técnicas de sensoriamento são um meio prático e barato de se obter informações sobre parâmetros de interesse agrônômico, sendo os sensores ópticos uma alternativa para a avaliação da resposta de culturas agrícolas à sua adubação nitrogenada. Para a otimização da eficiência do uso de nitrogênio por culturas agrícolas, algumas estratégias de adubação se baseiam na coleta de dados espectrais em alta frequência no campo, utilizando-os para entender a variabilidade espacial do estado de nutrição da planta com este nutriente. Para a cana-de-açúcar, apesar da efetividade de sensores ópticos em identificar alguns parâmetros desta cultura, ainda há a dificuldade de estabelecer relações com o seu Teor Foliar de Nitrogênio (TFN). Neste contexto, o presente trabalho acompanhou com sensor óptico hiperespectral (VisNIR) o desenvolvimento do dossel de cana-de-açúcar ao longo de seu ciclo, com o objetivo de avaliar temporariamente a relação entre a sua resposta espectral de reflectância e o seu TFN. Para tanto, foi avaliada uma área experimental com 28 parcelas de cana-de-açúcar, submetidas a tratamentos com diferentes doses de adubação nitrogenada. Ao longo do ciclo da cultura, avaliou-se a sua altura, o TFN e a sua resposta espectral de 400 a 900 nm; ao final do ciclo, foi estimada também a produtividade final de cada parcela. Para a avaliação do comportamento espectral da cultura em função da adubação nitrogenada e de seu desenvolvimento no campo, primeiramente, realizaram-se análises de variância (ANOVA) para a altura, o TFN e as diferentes regiões espectrais e, em um segundo momento, análises descritivas e a análise de componentes principais foram conduzidas, ambas sobre os dados espectrais. Em seguida, foram aplicadas diferentes metodologias para a análise quantitativa dos espectros para a predição do TFN. Nessas análises quantitativas, buscou-se avaliar o período ideal do desenvolvimento da cana-de-açúcar para avaliações espectrais de seu TFN serem aplicadas, assim como comprimentos de onda e índices de vegetação (IVs) específicos com relações satisfatórias com o TFN. Os resultados obtidos pelo presente trabalho mostraram possível uma razoável predição do TFN da cana-de-açúcar através de espectroscopia in situ, contudo, esta avaliação só foi possível ao redor de 144 Dias Após o Corte (DAC), momento em que a cultura ainda apresentava resposta do TFN à adubação nitrogenada e no qual o dossel de plantas já estava desenvolvido o suficiente para interromper a influência do solo na leitura espectral. Os IVs avaliados que mais se destacaram para a predição do TFN utilizaram os comprimentos de onda de 490 nm da região do verde; 590 nm da região do laranja; 647 e 652 nm da região do vermelho; 730 nm da região do *red-edge*; 780 e 880 nm da região do infravermelho próximo. Por fim, o IV que mais se destacou foi o NDRE, índice já sugerido pela literatura com bons resultados para a determinação da biomassa da cana-de-açúcar.

Palavras-chave: 1. Sensoriamento 2. VisNIR 3. Teor Foliar de Nitrogênio 4. Índices de Vegetação

ABSTRACT

In situ reflection spectroscopy in the evaluation of the sugarcane nitrogen response

In agriculture, sensing techniques are a practical and inexpensive way to obtain information on agronomic parameters. Optical sensors can be used as a tool to evaluate the response of agricultural crops to nitrogen (N) fertilization. In order to optimize the efficiency of N use in agricultural crops, some fertilization strategies are based on the collection and analysis of high frequency spectral data in the field to understand the spatial variability of N status of plants. Despite the effectiveness of optical sensors in identifying some agronomic parameters of the sugarcane, establishing relations between these data and the Leaf Nitrogen Content (TFN) of the sugarcane is still quite challenging. To address this issue, in this work the development of the sugarcane canopy was monitored during its cycle with a hyperspectral optical sensor (VisNIR), with the aim of evaluating the relations between its spectral reflectance response and its TFN in time. For this, an experimental area with 28 plots of sugarcane submitted to treatments with different doses of nitrogen fertilization was evaluated. Throughout the crop year were evaluated its height, TFN and spectral response from 400 to 900 nm; at the end of the cycle, the final yield of each plot was also evaluated. To begin with, the analysis of variance (ANOVA) for height, TFN and the different spectral regions was performed to assess the spectral behavior of the crop as a function of nitrogen fertilization and its development in the field. Furthermore, a descriptive analysis and analysis of principal components were conducted, both on spectral data. In addition to this, different methodologies were applied for the spectral quantitative analysis for the prediction of TFN. The aim of these quantitative analyses was to determine the ideal period of sugarcane development in order to apply spectral evaluations of its TFN and to find specific wavelengths and Vegetation Index (IVs) with satisfactory relations with the TFN. The results obtained by the present work showed a reasonable prediction of the sugarcane TFN by in situ spectroscopy. However, this evaluation was only possible around 144 Days After Harvest (DAC). During this period, the culture showed a response of the TFN to N fertilization and the canopy of plants was already developed enough to interrupt the influence of the soil in the spectral reading. The evaluated IVs that showed better results for the TFN prediction used the wavelengths 490 nm of the green region; 590 nm of the orange region; 647 and 652 nm of the red region; 730 nm of the red-edge region and; 780 and 880 nm of the near infrared region. The IV that showed the best result for the TFN prediction was the NDRE, vegetation index, which was already suggested by the literature with good results for the determination the sugarcane biomass.

Keywords: 1. Sensing 2. VisNIR 3. Leaf Nitrogen Content 4. Vegetation Index

1. INTRODUÇÃO

No Brasil, é evidente a importância do setor canavieiro para a sua economia, tendo em vista que o país é hoje o maior produtor mundial desta cultura. Foram cultivados 11,24 milhões de hectares com este cultivo em todo o país na safra 2015/16 (IBGE, 2016) e, segundo o levantamento nacional realizado pela Companhia Nacional de Abastecimento (CONAB, 2015), estima-se produzir na safra de 2015/16 um total de 655,9 milhões de toneladas, 23,9 milhões de toneladas a mais que a safra anterior.

Em paralelo, este setor se encontra em um cenário de grande expansão e evolução tecnológica, com crescente interesse em abordagens de Agricultura de Precisão (AP). Grego et al. (2014), analisando a aplicação de técnicas de AP na cultura da cana, concluem que o gerenciamento desta cultura, se for levada em consideração a sua variabilidade espacial, traduz-se em uma nova filosofia de trabalho, capaz de otimizar a sua produção agrícola, assim como se potencializam a competitividade e a sustentabilidade de sua cadeia produtiva.

Não obstante, apesar da importância da cultura da cana-de-açúcar, questões sobre a sua fisiologia e cultivo ainda necessitam ser esclarecidas. Dentre elas, recebe destaque a sua adubação nitrogenada, prática que ainda é um grande desafio devido à complexa interação deste nutriente com o solo e a própria cultura (THORBURN et al., 2011).

Em condições tropicais, graças à dinamicidade do nitrogênio (N) no solo, análises de solo para a avaliação da quantidade disponível deste nutriente às culturas não são realizadas, pois não há um método eficiente que o mensure. Assim, no Brasil, a adubação nitrogenada na cultura de cana-de-açúcar é tipicamente realizada em taxas uniformes e com dose de N baseada na expectativa de produção que se almeja alcançar em um determinado talhão (AMARAL; MOLIN, 2014). Produtividade, ademais, que são frequentemente não atingidas (THORBURN et al., 2011).

Tornam-se claras 2 limitações nesta prática de adubação nitrogenada, as quais consequentemente conduzem a uma baixa eficiência de uso de N pelas culturas, tipicamente oscilando entre 10 e 35% em cana soca (FRANCO et al., 2011). A primeira delas se relaciona às calibrações entre a dose de N a ser aplicada e produções almejadas. A maioria destas calibrações não consideram o histórico de adubação na área, tampouco as particularidades das diferentes variedades de cana, sistema de cultivo, nem tipo de solo, refletindo em grandes variações na literatura em relação à melhor dose a ser aplicada. A segunda limitação se refere às aplicações de maneira uniforme no talhão agrícola, ignorando a sua variabilidade intrínseca, o que tem como consequência a sub ou superfertilização de algumas partes de sua área.

Estas dificuldades induzem a aplicações de adubos nitrogenados em altas quantidades que, por conseguinte, aumentam os riscos ambientais de contaminação de recursos hídricos (EICKHOUT et al., 2006) e ampliam as emissões de óxido nitroso, gás causador do efeito estufa (BOUWMAN et al., 2002). A aplicação de fertilizantes em sítio-específico é uma alternativa já conhecida para o aumento da eficiência do uso de N por culturas agrícolas e, portanto, para a diminuição de riscos de contaminação do meio ambiente (HEEGE et al., 2008). Mediante esta técnica, a aplicação do insumo

é realizada em taxa variada, sendo direcionada conforme às necessidades locais das plantas dentro do talhão.

Uma possibilidade para se manejar a adubação nitrogenada da cana-de-açúcar em sítio-específico seria por meio da utilização de métodos que permitam o mapeamento da diagnose foliar. Assim, a avaliação da variabilidade espacial do estado nutricional da planta seria oportunizada, possibilitando, por sua vez, o acompanhamento e a avaliação de um programa de adubação. O Teor Foliar de Nitrogênio (TFN) pode ser utilizado tanto para a comparação com valores padrões estabelecidos para a espécie vegetal de interesse, quanto para o cálculo da quantidade de N extraído pela cultura, variáveis importantes para determinar estratégias de adubação.

Porém, é sabido que o mapeamento de parâmetros agrícolas envolvendo amostragens georreferenciadas e análises tradicionais de laboratório é inviabilizado pelos custos e tempo demandados entre a coleta, análise e geração dos mapas em nível de fazenda. Além disso, a análise de folha tradicional em laboratório envolve a utilização de reagentes químicos, o que gera resíduos e propensão a contaminação ambiental. Neste sentido, a utilização de sensores tem sido sugerida como alternativa para o preenchimento da lacuna de dados encontrada no planejamento da produção agrícola (IZNAGA et al., 2014). Esta estratégia envolve a calibração de modelos representativos da(s) área(s) de interesse, tendo-se como referência as análises tradicionais, e a posterior aplicação daqueles na estimativa dos atributos com base apenas na resposta espectral das amostras, abordagem esta que permite a intensificação massiva da amostragem e a caracterização da variabilidade da cultura no campo.

Os primeiros sensores ópticos para monitoramento de culturas agrícolas, desenvolvidos nos Estados Unidos e na Europa, utilizavam radiômetros passivos, isto é, equipamentos que utilizam a energia solar como fonte de radiação. A dificuldade de compensação da variabilidade espacial e temporal da iluminação do ambiente (SOUZA et al., 2010) conduziu ao desenvolvimento de sensores ópticos ativos, que trabalham com a sua própria fonte de radiação (HOLLAND et al., 2012), respondendo somente a ela, ou seja, não são influenciados pela radiação solar (SUDDUTH et al., 2015).

Por outro lado, sensores ativos apresentam resolução espectral limitada, ou seja, trabalham apenas com comprimentos de onda específicos. Tais comprimentos de onda expressam resultados satisfatórios para a predição de parâmetros das culturas agrícolas para as quais foram desenvolvidos. Todavia, eles podem não revelar o mesmo desempenho ao serem aplicados a novas culturas com características fisiológicas particulares, como a cana-de-açúcar. Assim, para estudos com uma caracterização detalhada do comportamento espectral da cana, buscando comprimentos de onda específicos que possam apresentar melhores relações com o TFN, ainda é necessária a utilização de sensores hiperespectrais, os quais são passivos.

No Brasil, estudos desenvolvidos para a cultura da cana-de-açúcar ainda não obtiveram resultados consistentes de boas determinações do TFN a partir da resposta espectral desta cultura. Todavia, trabalho realizado por Miohokasap et al. (2012), na Tailândia, utilizando um espectrorradiômetro VisNIR (sensível de 400 a 2500 nm) obteve predições satisfatórias (R^2 superior a

0,7) para o TFN da cultura da cana-de-açúcar, abrindo precedentes para utilização do sensoriamento hiperespectral para este fim em condições brasileiras.

A dificuldade de se conseguir boa modelagem entre dados espectrais e TFN também foi constatada por trabalhos de Cao et al. (2013) e Cao et al. (2015) para a cultura do arroz. Em contrapartida, para esta cultura, pesquisas desenvolvidas por Stroppiana et al. (2009), utilizando sensor de reflectância hiperespectral, identificaram correlações satisfatórias entre a concentração de N no dossel de plantas e IVs envolvendo 2 comprimentos de onda da região do visível (verde e azul). Estes autores defendem que o uso de IVs com combinações entre comprimentos de onda específicos na região do visível podem melhorar substancialmente a predição do TFN, hipótese que também é defendida por Hansen e Schjoerring (2003).

A partir do exposto, geram-se os seguintes questionamentos: seria possível por meio de dados hiperespectrais do dossel de cana-de-açúcar avaliar o seu TFN? IVs envolvendo apenas regiões do visível teriam mais potencial para esta predição? Qual seria o melhor momento do desenvolvimento da cultura para esta avaliação? Levando em consideração estas questões, surge o interesse do presente trabalho, o qual acompanhou com sensor óptico hiperespectral (VisNIR) o desenvolvimento do dossel de cana-de-açúcar, objetivando avaliar temporalmente a relação entre a sua resposta espectral de reflectância e o seu TFN.

2. REVISÃO BIBLIOGRÁFICA

2.1. Sensoriamento na agricultura

Técnicas de sensoriamento possibilitam obter informações sobre determinado alvo, utilizando um sensor para tal. Sensores podem ser conceituados como dispositivos capazes de responder a um estímulo físico ou químico do alvo sensoriado, sendo capaz de mensurá-lo. Este estímulo, por sua vez, relaciona-se às propriedades físico-químicas intrínsecas deste alvo, o que permite a obtenção de resultados qualitativos e quantitativos de forma mais rápida e barata que métodos tradicionais de análise, viabilizando assim uma maior quantidade de pontos amostrais (VISCARRA ROSSEL et al., 2011).

A utilização de sensores de maneira remota voltados ao levantamento e monitoramento dos recursos da superfície terrestre é uma das aplicações mais tradicionais de sensoriamento, amplamente utilizada nas mais diversas áreas de estudo. Considerada como uma ciência, o Sensoriamento Remoto (SR) se caracteriza pela aquisição de informações sobre objetos a partir da detecção de alterações que estes impõem ao campo eletromagnético (JENSEN, 2009; NOVO, 2010), obtendo informações sobre este sem o contato físico direto com o mesmo (BROWN et al., 2006).

Desde a sua origem ao redor de 1860, quando as primeiras fotografias aéreas foram utilizadas para mapeamento topográfico, o SR sempre esteve com certa constância atrelado a mudanças de paradigmas devido aos exponenciais avanços tecnológicos de suas áreas afins. Jensen (2009) menciona em seu trabalho que além dos progressos na tecnologia de construção de sensores que ficaram mais sensíveis, houve também melhorias das telecomunicações e informática. Estes avanços tecnológicos contribuem para aproximar os usuários de dados de sensoriamento ao processo de desenvolvimento de suas aplicações, uma vez que aqueles deixam mais acessíveis os próprios sistemas sensores, por sua redução de custo (GALUSZKA et al., 2015), assim como pelas ferramentas de análise espacial, que permitem agregar valor às informações derivadas dos sensores (NOVO, 2010).

Na agricultura, com a expansão de sensores portáteis embarcados em plataformas terrestres, trabalhando diretamente no campo, em contato direto ou próximos ao alvo sensoriado (solo ou planta), alguns autores vêm referindo-se a esta técnica como Sensoriamento Proximal (VISCARRA ROSSEL; McBRATNEY, 1998) ou, ainda, Sensoriamento Remoto in situ (JENSEN, 2009). Entre os princípios de funcionamento de sensores aplicados diretamente no campo para análises da vegetação predominam o uso de sensores ópticos, principalmente mensurando a reflectância do dossel de plantas (STONE et al., 1996; HEEGE et al., 2008; PORTZ et al., 2012a). No entanto, na literatura também podem ser encontrados alguns trabalhos empregando sensores com princípios de funcionamento mecânico para inferências quantitativas sobre a variabilidade de biomassa em culturas agrícolas, tais como trigo e cevada (HEEGE et al., 2008; THOELE; EHLERT, 2010). Estes sensores de biomassa se baseam na utilização de um pêndulo instalado junto ao trator que, em contato com a vegetação, sofre maior ou menor resistência para o seu deslocamento que,

por sua vez, aumenta ou diminui o seu ângulo de inclinação em função da biomassa da vegetação presente.

Uma outra possibilidade para o sensoriamento da vegetação são sensores de fluorescência de clorofila. Estes equipamentos, apesar de apresentarem princípio de funcionamento óptico, diferenciam-se dos tradicionais sensores ópticos de reflectância, pois utilizam-se de uma fonte de laser para induzir a emissão de fluorescência da amostra vegetal analisada (LEE; EHSANI, 2015; MOLIN et al., 2015). A aplicação destes sensores para a avaliação do estado nutricional da vegetação é uma possibilidade para tentar-se eliminar o efeito da biomassa, presente nos dados coletados por sensores ópticos de reflectância, avaliando apenas o teor de clorofila (HEEGE et al., 2008).

Quanto às classificações dos sensores ópticos, vale mencionar 2 outras importantes classificações. A primeira diz respeito à fonte de energia utilizada e, a segunda, ao poder de resolução espectral do sistema sensor. Quanto à origem da fonte de radiação, sensores podem ser classificados como ativos, quando estes produzem a sua fonte de radiação eletromagnética utilizada, ou passivos, quando a fonte de energia utilizada é externa ao sistema sensor (JENSEN, 2009). Já quanto ao poder de resolução espectral, um sensor pode ser multiespectral, quando este é sensível apresenta apenas algumas faixas do espectro eletromagnético, mensurando o estímulo de alguns comprimentos de onda específicos; ou hiperespectral, quando este permite a aquisição de espectros contínuos, mensurando o estímulo em vários comprimentos de onda consecutivos (NOVO, 2010).

Desta forma, sensores passivos hiperespectrais são dependentes de condições climáticas favoráveis e estáveis para que as características de iluminação não sofram alterações entre o momento que o sensor é calibrado e o momento em que os espectros dos alvos de interesse são coletados (JENSEN, 2009). No entanto, quando cuidados são tomados com a calibração dos aparelhos, estes apresentam a grande vantagem de serem hiperespectrais. A sua alta resolução espectral permite investigar a resposta da vegetação em bandas espectrais estreitas (narrowbands) e em uma ampla faixa do espectro, possibilitando a determinação de IVs mais acurados (THENKABAIL et al., 2010; MULLA, 2013).

Considerando a aplicação de sensores ópticos para o monitoramento do estado nutricional de N em dossel de plantas, os primeiros sistemas desenvolvidos nos Estados Unidos (STONE et al., 1996) e na Europa (HEEGE; REUSCH, 1996) utilizavam radiômetros passivos multiespectrais, isto é, equipamentos que utilizam a energia solar como fonte de radiação. A dificuldade de compensação da variabilidade espacial e temporal da iluminação do ambiente (SOUZA et al., 2010) conduziu ao desenvolvimento de sensores ópticos ativos, que trabalham com a sua própria fonte de radiação (HOLLAND et al., 2012) e que respondem somente às variações de sua própria fonte de radiação, não sendo influenciados pela radiação solar (SUDDUTH et al., 2015).

Por outro lado, devido à sua característica multiespectral, sensores ativos apresentam resolução espectral limitada, ou seja, eles trabalham apenas com comprimentos de onda específicos. Tais comprimentos de onda expressam resultados satisfatórios para a predição de parâmetros das culturas agrícolas para as quais eles foram desenvolvidos. Todavia, conforme já comentado, eles podem não revelar o mesmo desempenho ao serem aplicados a novas culturas com características

fisiológicas particulares, o que justifica a utilização de sensores hiperespectrais passivos para estudos que busquem comprimentos de onda específicos, possivelmente, mais bem correlacionados com a variável de interesse.

Segundo Goltz (2005), os espectros obtidos com sensor passivo podem variar de acordo com fatores como: a posição do sol (azimute solar), elevação solar (ângulo de elevação solar), direção de apontamento do sensor (em relação ao nadir), e, no caso da vegetação, por parâmetros biofísicos (teor de umidade, taxa de fotossíntese, estágio de desenvolvimento). Neste sentido, a observação de uma curva espectral de um alvo sem o conhecimento das condições de obtenção não fornece informações suficientes sobre o mesmo, sendo de extrema importância a correta calibração do sensor utilizado (JENSEN, 2009). Ben Dor et al. (2015) ressalta em seu trabalho que a replicação de modelos utilizando reflectância espectral e, inclusive o sucesso de bibliotecas espectrais, só serão possíveis se houver a criação de protocolos de padronização para as análises espectrais, os quais devem minimizar efeitos de fatores aleatórios e sistemáticos¹ que influenciam no albedo das curvas coletadas.

Em síntese, o uso de sensores na agricultura permite estimar de forma prática, barata e indestrutível parâmetros biofísicos de culturas agrícolas (ANDRADE et al., 2014) e atributos físico-químicos do solo (DEMATTE et al., 2015; DEMATTE et al., 2016). Ao se associar estes dados a informações de posição geográfica, torna-se possível representar e avaliar a variabilidade espacial do campo agrícola, abrindo portas à aplicação de diferentes abordagens de AP.

Um dos grandes desafios da AP está em obter informações acuradas de parâmetros do solo e da planta com suficiente frequência espacial e temporal, possibilitando o entendimento confiável da variabilidade espacial presente no campo. Desta forma, como a aquisição destas informações com uma alta densidade amostral, utilizando-se de métodos tradicionais, faz-se pouco prática e cara, há a necessidade do uso de técnicas de sensoriamento para tal (MOLIN et al., 2010; JESUS; GALVANIN, 2013). Molin et al. (2015) citam em seu trabalho que uma das grandes vantagens das ferramentas de sensoriamento em AP está relacionada à sua capacidade de coletar uma quantidade muito maior de dados do que aquela permitida pelas técnicas tradicionais de amostragem georreferenciada.

Devido ao recente e rápido progresso tecnológico na área de sensores, trabalhos recentes têm proposto o uso destes equipamentos diretamente no campo, visando a análises práticas, baratas e com resultado em tempo real sobre diferentes tipos de amostras do meio ambiente (GALUSZKA et al., 2015). Dhawale et al. (2015) destacam que, para a sua aplicação no campo, sensores devem ser compactos, resistentes e permitir uma predição acurada com o mínimo possível de preparo de amostra. Diferentes pesquisadores acreditam que, embora o desempenho analítico de campo apresentado pelos sensores portáteis tenham sido, de maneira geral, menos eficientes em comparação aos seus equivalentes em laboratório, esta falta de exatidão é compensada pela possibilidade de aumento massivo do número de amostras analisadas em campo, propiciando, consequentemente, uma visão espacial mais fiel da variabilidade destes atributos (GALUSZKA et al.,

¹ Segundo Ben Dor et al. (2015), os fatores sistemáticos são todos aqueles que influenciam a intensidade das curvas espectrais, mas que podem ser estabilizados ao se utilizar algum protocolo de padronização, como fatores relacionados aos equipamentos utilizados, à geometria utilizada durante a aquisição espectral, etc.

2015; MOLIN et al., 2015). Além disso, é de se esperar que o desenvolvimento tecnológico permita uma constante evolução na qualidade destas análises aplicadas in situ.

Além da praticidade e economia do método, o sensoriamento também se destaca por sua característica não destrutiva de análise, o que permite a caracterização de parâmetros da vegetação durante o seu ciclo vegetativo no campo (WRIGHT et al., 2004; POVH, 2007). Cao et al. (2015) ressaltam a importância de se aplicar estratégias para avaliar a resposta da planta, durante a safra, ao programa de adubação adotado. Esta prática se faz importante, pois ela permite verificar a ocorrência de deficiências, toxidez ou desequilíbrio de nutrientes (KURIHARA et al., 2005); avaliações importantes, uma vez que a disponibilização de nutrientes à cultura promovida pelo solo pode apresentar oscilações devido a variações das condições atmosféricas, de precipitação e do próprio solo.

Outro importante aspecto de sensores embarcados com princípio de funcionamento compatíveis com trabalhos in situ, citado por Stone et al. 1996 como uma abordagem futurística, é a possibilidade de permitir diagnósticos instantâneos, permitindo a sua associação com sistemas que possibilitam intervenções em tempo real. Esta utilização traz, indiscutivelmente, grande praticidade aos trabalhos de campo. Pesquisadores têm concordado que o ajuste de técnicas de sensoriamento voltadas à aplicação em sítio específico, utilizando diagnóstico e intervenção em tempo real, e evitando os custos tradicionais de amostragem e análises de laboratório, são um dos principais objetivos dos estudos da área (STONE et al., 1996; SAWYER, 1994).

Em síntese, sensores ópticos são equipamentos capazes de medir a energia radiante após esta interagir com determinado alvo e, por meio do comportamento destes sinais eletromagnéticos, eles permitem identificar e entender o objeto sensoriado. Na agricultura, a sua resposta pode ser aplicada para a avaliação de parâmetros relacionados ao estado nutricional de N da planta durante o seu ciclo no campo, permitindo subsidiar fertilizações nitrogenadas. Este método se destaca, pois ele permite: desenvolver estratégias de adubação nitrogenada, levando em consideração a variabilidade do potencial de reposta da cultura agrícola; realizar o diagnóstico e intervir em tempo real; e detectar a variabilidade de resposta à adubação em toda a área cultivada de maneira prática e não destrutiva.

2.2. Considerações sobre a adubação nitrogenada na cana-de-açúcar

A recomendação de fertilização com N que consta nas tabelas de adubação nacionais é um dos poucos casos em que não se leva em consideração a análise de solo. Não obstante, Raij (2011) menciona 4 procedimentos fundamentais para o manejo eficiente desta adubação, sendo eles: (i) levar em consideração o histórico da área, que pode fornecer informações sobre a resposta das culturas ao N; (ii) adubar de acordo com a produtividade esperada; (iii) aplicar o adubo nitrogenado em parcelas, para se evitar perdas por lixiviação; (iv) e garantir o fornecimento do nutriente em estágios mais desenvolvidos da cultura.

Na cultura de cana-de-açúcar – considerada semiperene por permanecer no campo em média por um ciclo de 5 anos – o N é um dos nutrientes limitantes à produtividade e longevidade das soqueiras de cana-de-açúcar (VITTI, 2003). Portanto, é importante pensar nos efeitos das adubações trazidos corte após corte (PENATTI, 2013). A alta produtividade de biomassa desta cultura está, na

maioria da vezes, associada a aplicações substanciais de adubos nitrogenados (ROY et al., 2006), sendo um desafio manter os altos níveis de produção, minimizando o impacto do uso destes fertilizantes (THORBURN et al., 2011).

Ademais, são raros os relatos em que a cultura utiliza mais de 40% do nitrogênio do fertilizante no final de seu ciclo agrícola (FRANCO et al., 2008). Parte deste baixo aproveitamento é atribuído à intensa imobilização microbiológica deste nutriente em solos que contêm material vegetal de elevada relação C:N (GAVA et al., 2001). O N imobilizado é, dessa forma, armazenado no solo, tornando-se uma potencial fonte residual deste nutriente para a cultura em seus ciclos subsequentes (VITTI et al., 2007).

Apesar da comprovada importância do N para a cana-de-açúcar, isso não é suficiente para prever respostas generalizadas às aplicações do nutriente. A cultura canavieira nem sempre costuma responder às adubações nitrogenadas (FRANCO et al., 2011; LOFTON et al., 2012). Segato et al. (2006) atribuem a ausência de resposta da cana-planta à adubação nitrogenada, à mineralização da matéria orgânica que ocorre durante o preparo do solo, às reservas existentes no tolete e ao sistema radicular extenso e profundo. Além disso, a cana-de-açúcar forma associações com bactérias fixadoras do gás nitrogênio (N_2) presente no ar atmosférico (URQUIAGA et al., 1992).

Vale lembrar também que solos cultivados com cana são frequentemente beneficiados com a adubação utilizando a vinhaça – resíduo da indústria canavieira – e também com a presença de grande quantidade de palhada, deixada sobre o solo após a colheita sem queima (PENATTI, 2013), o que aumenta a demanda deste nutriente, porém favorece seu efeito residual.

Em razão da falta de um método confiável para a avaliação do teor de N em solos tropicais, a adubação nitrogenada, no Brasil, é recomendada utilizando-se de curvas de respostas médias previamente calibradas em experimentos agronômicos com diferentes doses de N. Estas calibrações representam o comportamento médio da produtividade da cultura em relação às doses de N aplicadas, subsidiando a tomada de decisão da quantidade de N a ser aplicada (RAIJ, 2011). No entanto, tal método não conduz a uma adubação eficiente, pois além de ele não levar em consideração o histórico da área, usualmente, as aplicações são realizadas de maneira uniforme no talhão agrícola, o que tem como consequência a sub ou superfertilização de algumas partes da área agrícola (BREDEMEIER; SCHMIDHALTER, 2005).

Ademais, existem grandes variações na literatura em relação à melhor dose a ser aplicada, podendo variar de 60 a 140 kg de N ha^{-1} , sendo que estas diferenças estão diretamente ligadas à variedade, tipo de solo, região de estudo e sistema de cultivo (KORNDÖRFER et al., 2002; FRANCO et al., 2010).

Uma alternativa simples para o manejo da adubação nitrogenada da cana com gestão localizada de insumos seria por meio da adoção do mapeamento da sua produtividade. Nesta abordagem, utilizar-se-ia a informação do(s) mapa(s) de produtividade para se conhecer a variabilidade do potencial produtivo (produtividade esperada) e assim variar a dose aplicada conforme as curvas de resposta propostas nos manuais de fertilidade. Molin et al. (2015) mencionam que, a princípio, técnicas de gestão localizada de fertilizantes resultam na melhor distribuição deste, sem que haja redução ou aumento de seu consumo – o que, por sua vez, já poderia resultar em ganhos

de produtividade e/ou maior uniformidade do solo e planta. Os autores expressam tal raciocínio pelo fato de que nas aplicações uniformes, se a investigação sobre a área for bem-sucedida, a dose a ser aplicada será a mesma da dose média da aplicação localizada, uma vez que o método de recomendação tem a mesma origem (cálculo do insumo a partir dos manuais de fertilidade).

Outra possibilidade para se manejar a adubação nitrogenada da cana-de-açúcar de maneira mais eficiente é valendo-se de métodos de diagnose foliar. Segundo Kurihara et al. (2005), a interpretação da análise foliar possibilita verificar a ocorrência de deficiências, toxidez ou desequilíbrio de nutrientes, permitindo assim a avaliação da estratégia de adubação adotada, de modo a promover uma adubação mais equilibrada. Conforme Malavolta et al. (1997), a avaliação do estado nutricional das plantas normalmente é realizada por análises foliares, tendo-se em vista que a folha recém-madura é o órgão que, como regra geral, responde melhor às variações no suprimento do nutriente. Nas folhas, ocorrem as principais reações metabólicas e as alterações fisiológicas decorrentes de distúrbios nutricionais normalmente tornam-se mais evidentes (KURIHARA et al., 2005).

Ripoli (2007) comentam que, para a eficiência do método, a amostragem foliar deve levar em consideração aspectos como a uniformidade da área, quanto ao tipo de solo, variedade, idade, tratos culturais e tipo de folha. No caso da cana-de-açúcar, recomenda-se coletar sua folha +1, utilizar os 20 cm centrais, desprezando-se a nervura, e realizar a coleta quando a cultura estiver em seu maior desenvolvimento vegetativo, sendo em cana-planta de ano aproximadamente 6 meses após a germinação e em cana-soca de ano 4 meses após o corte (VITTI; MAZZA, 2002).

Para comparação e interpretação dos resultados da análise foliar para a cultura da cana, Raij et al. (1997) propuseram a faixa de 18 a 25 g kg⁻¹ como quantidade adequada deste nutriente na folha. Rozane et al. (2008), analisando a influência de diferentes folhas e a sua época de amostragem sobre o TFN da cana-de-açúcar, concluíram que a amostragem da folha +1, coletada aos 4 meses após o corte da planta, foi o mais adequado para a diagnose foliar desta cultura. Destaca-se também que os valores de TFN encontrados pelos autores ficaram abaixo dos valores ótimos propostos por Raij et al. (1997). Por outro lado, abordagens que envolvem o mapeamento da variabilidade agrícola para aplicações em taxa variada a partir de amostragens foliares da cultura não são economicamente viáveis, devido à necessidade de uma alta densidade de amostras para a representatividade da área.

Assim, uma alternativa para o manejo da adubação nitrogenada de culturas agrícolas que vem se consolidando é por meio da utilização de sensores ópticos de reflectância junto a algoritmos agrônômicos que transformam a informação coletada pelo sensor em dose de N a ser aplicada. Este método permite avaliar a resposta espectral do dossel da cultura durante o seu desenvolvimento na safra de maneira “limpa” e não destrutiva, permitindo usar diferentes estratégias para a adubação de cobertura a partir da interpretação das informações tomadas com o sensor.

2.3. Sensores ópticos aplicados ao auxílio da adubação de N na cana-de-açúcar

Devido à resposta de culturas agrícolas à adubação nitrogenada ser dependente do fornecimento de N pelo solo, o qual varia espacial e temporalmente, estratégias de manejo do N que incluam predições confiáveis da variabilidade do índice de resposta da cultura durante o ciclo

poderiam aumentar a eficiência no uso de N em cultivos agrícolas (JOHNSON; RAUN, 2003). A aplicação de fertilizantes em sítio-específico, subsidiada por informações tomadas por sensores, é uma alternativa já conhecida para o aumento da eficiência do uso de N por culturas agrícolas e, por conseguinte, para a diminuição de riscos de contaminação do meio ambiente (HEEGE et al., 2008).

Diversas pesquisas têm sido direcionadas ao desenvolvimento de algoritmos para a transformação da resposta de sensores em informação da quantidade de N a ser aplicada em culturas agrícolas, tais como o trigo (RAUN et al., 2002), milho (SOLARI et al., 2008; KITCHEN et al., 2010), algodão (OLIVEIRA et al., 2013), arroz (XUE et al., 2014) e cana-de-açúcar (AMARAL et al., 2015a).

Várias formas de uso das leituras dos sensores vêm sendo propostas, sendo que muitos destes algoritmos utilizam como dado de entrada a informação espectral do dossel de plantas em formato de IVs (SUDDUTH et al., 2015), que geralmente envolvem a região do visível e do infravermelho próximo (MOLIN et al., 2015), regiões de 370 a 699 nm e de 780 a 1.500 nm, respectivamente². Vem ganhando destaque também a utilização de dados de reflectância da região de transição entre o vermelho e infravermelho próximo, nomeada como *red-edge* (c. 700 a 779 nm).

Segundo Mulla (2013), quanto maior a energia absorvida pelos pigmentos, menor será o fator de reflectância na região do visível. Em contrapartida, a região do infravermelho próximo é influenciada pela arquitetura do dossel de plantas, estrutura do mesófilo foliar e número de camadas de folhas. Segundo Ponzoni et al. (2012), ao se aumentar o número de camadas, um maior fator de reflectância é observado – comportamento conhecido como Espalhamento Múltiplo ou, para alguns autores, Reflectância Aditiva. Assim, as regiões do visível e infravermelho próximo apresentam, respectivamente, fortes relações com pigmentos foliares e biomassa da parte aérea (PETERSON; RUNNING, 1989), ambas características relacionadas com a resposta da planta à nutrição de N.

Já a região do *red-edge*, segundo Heege et al. (2008), apresenta mais informações da biomassa dos dosséis de vegetação em comparação com as demais regiões do espectro eletromagnético. Conforme os autores, destacam-se para avaliação da biomassa da vegetação os comprimentos de onda de 706 e 755 nm.

Por outro lado, para que o comportamento espectral do dossel da cultura represente de fato a resposta da planta à adubação nitrogenada, é importante considerar o estágio de desenvolvimento em que ela se encontra para aplicação do sensor óptico. Portz et al. (2012b), concluem em seu trabalho que, para a cultura da cana-de-açúcar, o melhor estágio de desenvolvimento para a aplicação de sensores ópticos ocorre quando ela se encontra com altura de colmo entre 0,2 e 0,6 metros.

A aplicação de sensores ópticos em dosséis de plantas pouco desenvolvidos comumente não resultam na diferenciação espectral dos tratamentos que receberam diferentes doses de N (PORTZ et al., 2012a; AMARAL; MOLIN, 2011). Esta sensibilidade tardia da resposta espectral pode

² A definição dos limites das regiões espectrais varia de acordo com a fonte consultada. Neste trabalho, foram adotados os limites: de 370 a 399 nm para a região do violeta, de 400 a 489 nm para o azul, 490 a 559 nm para o verde, 560 a 589 nm para o amarelo, 590 a 629 nm para o laranja, 630 a 699 nm para o vermelho, 700 a 779 nm para o *red-edge* e de 780 a 1.500 nm para o infravermelho próximo; os quais se aproximam dos propostos por Novo (2010).

ser atribuída à ausência de tempo suficiente para a planta responder em produção de biomassa - principal parâmetro a que sensores de dosséis são sensíveis - e/ou devido à interferência do solo/palhada na resposta espectral, pelo fato de que em estágios iniciais é comum que a cultura ainda não tenha fechado seu dossel (AMARAL; MOLIN, 2014).

De maneira semelhante, há uma redução da sensibilidade de resposta espectral em dosséis de cana com maior biomassa na parte aérea, de modo que é dificultada a diferenciação da resposta da cana ao N aplicado a partir de dados espectrais (PORTZ et al., 2012a; PORTZ et al., 2012b; AMARAL, 2014). Este comportamento ocorre devido ao fenômeno da Reflectância Aditiva, o qual descreve o comportamento espectral da região do infravermelho próximo em função do número de camadas de folhas de um dossel de plantas qualquer (ganho de biomassa, no caso da cana-de-açúcar). O conceito menciona que o incremento da reflectância com a adição de camadas de folhas não é linear, apresentando acréscimos sempre menores, à medida que se aumenta o número de camadas de folhas (THENKABAIL et al., 2000; PONZONI et al., 2012). Assim, em estágios de maior desenvolvimento da cultura da cana há uma saturação da resposta espectral na região do infravermelho próximo e, conseqüentemente, de IVs que utilizam esta região, limitando a capacidade de avaliação da resposta da planta ao N com sensores ópticos.

2.3.1. Estudos envolvendo sensores ativos multiespectrais

No Brasil, estudos utilizando sensores ópticos multiespectrais na cultura da cana-de-açúcar mostraram resultados promissores de utilização de dados espectrais de dossel para: diferenciar doses de N aplicadas (INAMASU et al., 2006); estimar N extraído pela cultura (PORTZ et al., 2012a); estimar biomassa acumulada pela parte aérea e, conseqüentemente, estimar a sua produtividade (AMARAL; MOLIN, 2011; AMARAL, 2014). Porém, resultados consistentes para a predição do TFN ainda não foram obtidos.

Portz et al. (2012a) e Portz et al. (2012b), avaliando vários plantios comerciais desta cultura, encontraram excelentes relações (R^2 variando entre 0,67 e 0,94) para a predição do N extraído utilizando o sensor N-SensorTM ALS (Yara International ASA, Duermen, Alemanha), que trabalha com relações entre os comprimentos de onda 730 e 760 nm. Os resultados encontrados por estes autores foram obtidos com a cultura em estágio inicial de desenvolvimento, quando a planta apresentava altura entre 0,3 e 0,5 m (medida obtida do solo até a folha +1). Nestes trabalhos, os autores calcularam o N extraído pela cultura a partir da informação de seu TFN e de sua produção de massa seca, portanto apesar do N extraído ser função do TFN, ele também se relaciona com a produção de biomassa da planta, o que pode justificar as altas correlações obtidas com o espectro.

Amaral e Molin (2014), também avaliando plantios comerciais de cana-de-açúcar, encontraram correlações satisfatórias entre dados espectrais e a resposta de produtividade à aplicação de N. Os autores concluem que sensores ópticos de dossel são, de certa forma, sensíveis às diferentes doses de N aplicadas em campo, pois o nitrogênio absorvido influencia o acúmulo de biomassa na planta, principal fator que comanda o comportamento espectral desta cultura. Os autores ainda relatam que há uma dificuldade de se conseguir resultados consistentes da resposta

desta cultura à adubação de N por meio de sensores ópticos, pois existe nos campos de cana uma alta variabilidade ocasionada por fatores os quais são mais limitantes que o N, tais como compactação do solo, danos de colheita e estresses hídricos.

Explorando as relações entre índices de vegetação e a resposta de biomassa desta cultura, Amaral et al. (2015a) propuseram em seu trabalho um algoritmo para converter a resposta do sensor em doses de aplicação de N. A metodologia proposta pelos autores foge à maneira tradicional de se interpretar os dados obtidos com sensor óptico, proposta por Raun et al. (2005) e Holland e Schepers (2010), baseadas na adubação localizada de N para a cultura de cereais. Estas abordagens tradicionais direcionam aplicações mais altas deste nutriente em locais onde se apresentam menor resposta de vigor da cultura; em contrapartida, a metodologia de Amaral et al. (2015a) propõe doses mais altas de N aos locais com vigor de planta também alto. Os autores se justificam pelo fato de que o baixo desenvolvimento de biomassa da cultura da cana nem sempre é função da deficiência de N, em muitos casos, danos na planta causados no momento da colheita mascaram o efeito do N. Desta maneira, locais que apresentam maior vigor se mostrariam mais satisfatórios para o recebimento de altas doses de N, uma vez que a cultura está bem-establishada.

2.3.2. Estudos envolvendo sensores passivos hiperespectrais

Os estudos nacionais aplicando sensores multiespectrais em dosséis de cana-de-açúcar ainda não obtiveram resultados satisfatórios de correlação entre IVs e o TFN. A mesma dificuldade também foi constatada por trabalhos de Cao et al. (2013) e Cao et al. (2015) para a cultura do arroz, que obtiveram correlações entre IVs, obtidos com sensores ópticos multiespectrais, e o teor foliar de N com R^2 não superiores a 0,33. Em contrapartida, para esta mesma cultura, pesquisas desenvolvidas por Stroppiana et al. (2009), operando um sensor de reflectância hiperespectral, identificaram correlações satisfatórias (R^2 maior que 0,65) entre a concentração de N no dossel e IVs, os quais envolviam dois comprimentos de onda da região do visível (verde e azul). Os autores ainda comentam que o uso de IVs com combinações entre comprimentos de onda específicos da região do visível pode melhorar substancialmente a predição de variáveis relacionadas ao N na planta, tal como o TFN. Esta hipótese também é defendida por Hansen e Schjoerring (2003).

Na Tailândia, investigações conduzidas por Miahokasap et al. (2012), objetivando a predição do TFN em dosséis de cana-de-açúcar com sensor hiperespectral, mostraram resultados promissores. Os autores avaliaram o dossel de plantas com o espectrorradiômetro FieldSpec 3 (Analytical Spectral Devices – ASD, Boulder, CO, USA) e técnicas de mineração de dados (data mining), obtendo coeficientes de determinação superiores a 0,7 entre o TFN e IVs, os quais trabalhavam com comprimentos de onda específicos dentro da região do *red-edge*. No entanto, os resultados encontrados pelos autores citados foram obtidos quando a cultura se encontrava com 9 meses de idade e aproximadamente 3,5 metros de altura, momento tardio para intervenções na adubação desta cultura durante o ciclo produtivo em que ela foi avaliada. Por outro lado, esta pesquisa abre preceitos para utilização de sensores hiperespectrais como alternativa para a predição do TFN em dosséis de cana, ou então, como ferramenta para se obter IVs e comprimentos de onda

que sejam mais correlatos com esta variável, possibilitando uma futura adaptação de sensores multiespectrais ativos.

No Brasil, são recentes os estudos com sensores hiperespectrais em cana-de-açúcar. Martins (2016), em condições de laboratório, ao avaliar diretamente as folhas da cultura (coletadas aos 90 DAC – Dias Após o Corte) com sensor hiperespectral, encontrou resultados promissores (R^2 superiores a 0,6) para a predição do TFN. Por sua vez, Barros (2016), utilizando o mesmo sensor e avaliando dosséis de cana *in situ*, logrou resultados menos significativos (R^2 de 0,5), aos 146 DAC. Estes resultados preliminares ao serem comparados com os obtidos por Miahokasap et al. (2012) indicam que são necessárias investigações mais profundas com o sensoriamento hiperespectral aplicados à predição do TFN da cana, a fim de explorar e entender o real potencial potencial da técnica.

2.4. Análises de componentes principais para avaliações qualitativas de curvas espectrais

Análises qualitativas são realizadas com o intuito de identificar particularidades ao longo do espectro eletromagnético, tais como a ocorrência de diferentes intensidades de reflectância (albedo) e a presença de feições de absorção. Desta forma, elas também representam avaliações que possibilitam diferenciar dosséis de plantas e caracterizá-los qualitativamente quanto à variação dos parâmetros físico-químicos que os constituem.

Dentre as análises qualitativas multivariadas, a Análise de Componentes Principais (ACP) é uma das que se destacam. Ela é uma importante ferramenta de análise multivariada, sendo inclusive a base na qual se fundamentam outros métodos multivariados de análises de dados, por exemplo, a regressão em componentes principais e a regressão por mínimos quadrados parciais (PLSR – Partial Least Squares Regression). Além do mais, este é um recurso que permite revelar a presença de amostras anômalas, as relações entre variáveis e os agrupamentos entre amostras (LYRA et al., 2010).

A ACP é considerada como um método exploratório e que, em dados espectrais, permite identificar possíveis agrupamentos ou classes de amostras as quais possuem características semelhantes (NASCIMENTO et al., 2010; MULLA, 2013). O objetivo desta análise é averiguar um grande número de variáveis originais e encontrar as suas combinações, de forma a transformá-las e reduzi-las a um pequeno número de variáveis que sejam não correlacionadas na ordem de sua importância e que descreva a variabilidade dos dados (MANLY, 2008). Portanto, a ACP simplifica a análise de grandes conjuntos de dados, reduzindo-os a poucas variáveis as quais representam a variação dos dados originais, de modo que o novo conjunto de variáveis contém apenas informações importantes, criando-se novos eixos no espaço multidimensional, que são chamados de componentes principais (BROWN, 1995; NASCIMENTO et al., 2010).

A ACP consiste na realização de uma série de transformações matemáticas, em que um conjunto de dados de entrada com n variáveis e p indivíduos, após o processamento, produzirá outro conjunto de dados com p indivíduos, porém com um número de variáveis menor, estipulado no momento do processamento de dados. A implementação algébrica da ACP é dada pela Equação 1:

$$CP1 = (B1 \cdot e1,1) + (B2 \cdot e1,2) + \dots + (Bn \cdot e1,n) \quad (1)$$

$$CP2 = (B1 \cdot e2,1) + (B2 \cdot e2,2) + \dots + (Bn \cdot e2,n)$$

...

$$CPn = (B1 \cdot en,1) + (B2 \cdot en,2) + \dots + (Bn \cdot en,n)$$

Onde: CP1 a CPn são os valores dos pesos (*scores* ou autovalores) das componentes principais, B1 a Bn são os dados originais (valores de reflectância de cada um dos comprimentos de onda) e e1 a en são os autovetores.

Assim, percebe-se que associado a cada autovalor existe um conjunto de autovetores os quais servem como fatores de ponderação que definem o peso de cada dado original para uma determinada componente principal (CROSTA, 1992). Logo, em análises do comportamento espectral de alvos, os autovetores mostram a contribuição de cada comprimento de onda no autovalor de cada componente principal. Os autovalores e autovetores associados definem o novo conjunto de dados.

Por fim, a ACP tem se consolidado como ferramenta padrão para a redução da dimensão de dados e a determinação da intensidade dos efeitos de um certo atributo em estudos de caracterização do comportamento espectral de solos, plantas, minerais e rochas (SMITH et al., 1985; GALVÃO et al., 2001; MIPHOKASAP et al., 2012; DEBAENE et al., 2014).

2.5. Métodos para avaliações quantitativas da reflectância espectral

A espectroscopia nas regiões do VisNIR associada a métodos quimiométricos, permite a quantificação de diversos parâmetros físico-químicos do alvo sensoriado. Estes métodos dizem respeito à aplicação de análises estatísticas de regressão para a obtenção de modelos de determinação, a fim de estabelecer a predição de atributos de alvos específicos, baseando-se em suas informações espectrais. A quantificação de parâmetros bioquímicos do dossel de planta por meio das informações de reflectância espectral torna necessária a utilização de técnicas apuradas que produzam modelos matemáticos utilizados para predição destes valores (GOMEZ et al., 2008).

A quimiometria é a base para a manipulação de dados obtidos por espectroscopia de reflectância, de forma a utilizá-los para reconhecimento e classificação de padrões, monitoramentos, e, ainda, calibração e modelagem multivariada (WOLD et al., 2001; VISCARRA ROSSEL, 2008; MARETTO, 2011).

Um dos problemas práticos de se utilizar dados hiperespectrais para predição de variáveis se deve à utilização de uma grande quantidade de variáveis preditoras – que, naturalmente, apresentam alta colinearidade – para a coleta de uma única informação. Somado a este entrave, na maioria das vezes, o número de observações é menor que o número de variáveis preditoras. Desta forma, cuidados devem ser tomados com as técnicas de predição elegidas de maneira que estas explorem apenas as regiões do espectro as quais apresentam relações satisfatórias com o atributo a ser predito, evitando assim modelos sobreajustados.

Desenvolvida por Wold et al. (1983), a PLSR é uma técnica que tem sido amplamente utilizada em quimiometria para análises quantitativas a partir da reflectância espectral (VISCARRA

ROSSEL et al., 2006; IZNAGA et al., 2014). A PLSR também é um método de regressão multivariada que se destaca entre os demais por ser uma técnica de compreensão relativamente fácil; por ter a possibilidade de avaliar uma grande quantidade de variáveis preditoras (tal como curvas espectrais), evitando o fenômeno do sobreajuste (over-fitting); e por possuir boa disponibilidade de softwares estatísticos que realizam esta análise (TOBIAS, 1995).

Para predição da variável de interesse, a PLSR utiliza todo o espectro para obtenção de sucessivas Variáveis Latentes (VL), as quais maximizam a covariância entre as variáveis de predição (espectros) e de resposta (parâmetro de interesse). A partir de combinações entre estas novas variáveis, é gerado o modelo de regressão linear (VISCARRA ROSSEL; BEHRENS, 2010).

Assim, a PLSR manipula uma grande série de dados de maneira simultânea e lida com grande número de variáveis preditas que são altamente colineares (no caso, curvas espectrais) (VARMUZA; FILZMOSER, 2009). Além disso, o método é robusto, mesmo com interferência de ruídos ou ausência de dados; permite a predição do atributo de interesse com poucos componentes e, também, apresenta velocidade computacional do algoritmo favorável (VISCARRA ROSSEL, 2008).

Outro recurso utilizado para se evitar o fenômeno do sobreajuste é a redução da dimensão de dados utilizando métodos de seleção de variáveis. Um dos métodos que pode ser utilizado para este fim, quando se dispõe de mais observações que variáveis, é o de *Stepwise*. Segundo Glantz e Slinker (1990), este método permite estabelecer modelos de regressões mais confiáveis, pois o processo de entrada das variáveis dependentes é gradual e sequencial, isto é, uma variável de cada vez entra na equação de regressão, melhorando a habilidade de predição do modelo.

O método de *Stepwise* retira de forma gradativa as variáveis menos significativas estatisticamente em relação à variável a ser predita. Este processo ocorre até que as variáveis restantes sejam estatisticamente relevantes, ou seja, até que não haja melhora significativa do modelo ou não haja variáveis a serem retiradas. Esta técnica supõe que algumas variáveis não contribuam de forma expressiva com a resposta de todo o conjunto (DARVISHZADEH et al., 2008). Desta forma, este método é útil em situações que apresentam grandes bancos de dados com um alto número de variáveis independentes, permitindo identificar pequenos subgrupos de variáveis as quais melhor se correlacionam e determinam o valor da variável dependente (DEMATTÊ et al., 2015).

Outro método eficiente para a redução da dimensão de dados altamente correlacionados é a sparse Partial Least Square (sPLS). Ele, ao contrário do *Stepwise*, pode ser aplicado quando existem mais variáveis que observações. Ele tem como princípio a imposição de dispersão nas variáveis independentes, por meio dos princípios dos mínimos quadrados parciais (CHUN; KELES, 2010). Frequentemente, quando se trabalha com dados espectrais, dispõe-se de um número de variáveis maior que o de observações. Uma alternativa para se aplicar o método de *Stepwise*, neste caso, é reduzir o número de variáveis, utilizando a técnica sPLS.

Para a interpretação das quantificações dos atributos, necessita-se observar os valores de algumas figuras de mérito da regressão. Frequentemente, utiliza-se para tal, o coeficiente de determinação (R^2); a Raiz do Erro Quadrático Médio (RMSE), que expressa a acurácia do modelo, apresentando o valor de erro na mesma unidade de medida da variável; o Erro Relativo (do inglês, RE), que expressa o erro em porcentagem, tomando como referência a média dos valores de

referência e a Razão de Porcentagem de Desvio (RPD) (NANNI; DEMATTÊ, 2006; WETTERLIND et al., 2008; SHI et al., 2014).

Saeys et al. (2005) estabeleceram que valores de referência para avaliação do R^2 , em que valores oscilando entre 0,50 e 0,65 indicam a possibilidade de discriminação das altas e baixas concentrações do atributo, utilizando o modelo, enquanto que valores entre 0,66 e 0,86 e acima de 0,86 indicam modelos quantitativos de predição de atributos químicos do solo bons e excelentes, respectivamente. De maneira semelhante, Chang et al. (2001) estabeleceram valores de referência para a interpretação do RPD, em que valores menores que 1,40 indicam modelos não confiáveis; valores entre 1,40 e 2,00 indicam modelos razoáveis e valores superiores a 2,00, modelos excelentes que predizem de forma acurada o atributo.

3. MATERIAL E MÉTODOS

3.1. Área experimental

O experimento foi planejado e conduzido pela equipe do Instituto Agronômico de Campinas (IAC), como parte do projeto temático BIOEN/FAPESP no 2008/56147-1. A área experimental está localizada em um talhão da fazenda da Agência Paulista de Tecnologia dos Agronegócios (APTA) em Piracicaba, nas coordenadas geográficas 22°41'02" de latitude sul e 47°38'44" de longitude oeste, com referência no Datum WGS-84.

O solo do local foi classificado como Argissolo Vermelho-Amarelo. A variedade de cana IAC 95-5000 foi implantada nesta área no ano de 2013, sendo o presente experimento conduzido ao longo da safra 2014/2015, cana de primeira soca.

Para a execução de experimentos agrônômicos, o talhão foi dividido em 28 parcelas (unidades experimentais), cada uma composta por cinco linhas de cana, espaçadas a 1,5 m e com comprimento de 15 m. As parcelas foram instaladas com delineamento experimental de blocos aleatorizados, e os tratamentos consistiram em 4 diferentes níveis de adubação (0, 60, 120 e 180 kg ha⁻¹), sendo que os tratamentos com 60, 120 e 180 kg ha⁻¹ apresentaram 8 repetições e o tratamento-controle (0 kg ha⁻¹), 4 repetições.

Figura 1. Localização da área de estudo.

3.2. Coleta de dados

Ao longo do ciclo da cultura, foram coletadas informações da resposta espectral do dossel de plantas, da altura do colmo e do TFN; ademais, ao final do ciclo, também foi estimada a produtividade final da cultura para cada parcela. Para que a coleta de dados no interior de cada parcela fosse realizada sempre no mesmo ponto, 5 touceiras (subamostras) foram demarcadas com fitas plásticas, as quais consistiram nas unidades observacionais do experimento.

A primeira coleta foi realizada no dia 16 de dezembro de 2014, quando a cultura estava com 67 Dias Após o Corte (DAC) e apresentava altura média de colmo de 1 metro. Conforme apresentado pela Tabela 1, os dados espectrais, a altura e o TFN foram mensurados com intervalos de aproximadamente 1 mês, com coletas realizadas em diferentes estágios de desenvolvimento da cana-de-açúcar (Figura 2) estendendo-se até o mês da colheita (setembro de 2015). A coleta não foi realizada em intervalos mensais regulares, pois os parâmetros avaliados deveriam ser mensurados juntos à coleta de dados espectrais e o sensor utilizado era dependente de condições climáticas favoráveis.

O fim da tomada de dados mensais, que deveria ser determinado pela colheita da cultura, teve de ser realizado no mês de junho, pois no mês de julho grande parte das parcelas experimentais sofreram acamamento, deformando a estrutura do dossel de plantas, o que ocasionaria alterações nas leituras espectrais realizadas com o sensor, comprometendo a sua análise.

Tabela 1. Coleta de dados realizadas em campo.

Coleta	Informações tomadas	Data	DAC
C1	Espectral, altura e TFN	16/12/2014	67
C2	Espectral, altura e TFN	17/01/2015	99
C3	Espectral, altura e TFN	03/03/2015	144
C4	Espectral, altura e TFN	23/03/2015	164
C5	Espectral, altura e TFN	28/04/2015	200
C6	Espectral, altura e TFN	26/05/2015	228
C7	Espectral, altura e TFN	22/06/2015	255
Colheita	Produtividade	17/09/2015	342

Figura 2. Estágio de desenvolvimento da cultura no momento das coletas de dados.

3.2.1. Aquisição dos dados espectrais de dossel

Os dados espectrais de cada parcela foram sempre obtidos sobre as 5 plantas previamente marcadas; desta maneira, em cada coleta de campo eram obtidos um total de 140 espectros. Para o sensoriamento do dossel de plantas, foi utilizado o espectrorradiômetro HandHeld 2 (ASD – *Analytical Spectral Devices*, Boulder, EUA). Este equipamento é um sensor hiperespectral passivo que trabalha com comprimentos de onda do espectro visível ao infravermelho próximo (325 a 1075 nm), apresentando resolução espectral de 3 nm; contudo, informa a reflectância a cada 1 nm, produto da interpolação entre os valores mensurados.

O sensor apresenta ângulo de visada de 25° e, neste trabalho, para cada coleta foi posicionado a 1,5 m acima da altura média da cultura, proporcionando um campo de visada circular de aproximadamente 0,65 m de diâmetro e área de 0,34 m², conforme esquematizado pela Figura 3A. Para a realização das leituras espectrais ao longo do desenvolvimento da cultura, foi adaptado um suporte retrátil para a elevação do mesmo até a altura adequada (Figura 3B).

Figura 3. (A) Esquema da coleta de dados espectrais do dossel de cana-de-açúcar com sensor posicionado a 1,5 m acima do dossel; (B) Suporte retrátil adaptado ao sensor.

Conhecida a sensibilidade do sensor passivo, cuidados maiores foram tomados para a obtenção de dados espectrais com o intuito de minimizar os efeitos das variações da iluminação do ambiente. Assim, as leituras espectrais foram sempre realizadas em dias ensolarados, com a menor quantidade possível de nuvens, obedecendo ao intervalo entre as 10h e 14h, de forma semelhante aos trabalhos realizados por Mikhokasap et al. (2012) e Barros (2016), que também utilizaram um sensor hiperespectral passivo para a avaliação do dossel de cana. Ademais, impreterivelmente, antes de se iniciar o sensoriamento do dossel de plantas, realizava-se a calibração do espectrorradiômetro valendo-se da placa Lambertiana padrão que acompanha o aparelho. Recalibrações do sensor eram feitas sempre após a leitura de 10 parcelas experimentais, o que representava um tempo de aproximadamente 40 minutos entre calibrações. Quando, eventualmente, eram observadas

mudanças de intensidade da luz solar provocadas pela presença de nuvens, o trabalho era interrompido até que se estabilizava a intensidade de luz.

No processo de calibração, para a padronização da altura da placa Lambertiana em relação à ponta leitora do sensor, foi adaptada no suporte do aparelho uma base para o posicionamento da placa de calibração (Figuras 4A e B). A base foi posicionada abaixo do leitor do sensor, a uma distância de 15 cm, de modo que o campo de visada do aparelho ficasse totalmente preenchido pela placa. A caracterização do comportamento espectral de cada parcela foi realizada calculando-se a média dos espectros coletados sobre cada uma das 5 touceiras marcadas.

Apesar das curvas espectrais haverem sido mensuradas de 325 a 1075 nm, foi utilizado apenas o intervalo de 400 a 900 nm, devido a presença de grande intensidade de ruído no início e final das curvas espectrais.

Figura 4. (A) Base adaptada no suporte do sensor para posicionamento da placa Lambertiana; (B) Placa Lambertiana sobre o suporte.

3.2.2. Aquisição da altura de colmo, TFN e produtividade

No mesmo dia da coleta de dados espectrais, realizava-se a medição da altura das plantas e a coleta de folhas para obtenção do TFN. A altura das plantas foi mensurada em cada uma das touceiras previamente marcadas, medindo-se o colmo de maior altura e tomando a medida do solo até o ápice da folha-bandeira. A caracterização da altura de cada parcela foi realizada calculando-se a média das medidas de cada uma das 5 subamostras.

Para a caracterização das parcelas quanto ao seu teor foliar de nitrogênio, foram retiradas para análise 10 folhas de cada parcela. Foi colhida a primeira folha completamente expandida – lígula totalmente aberta – a partir do ápice da cultura, denominada como folha +1, bem aceita na literatura como folha diagnóstico para a cana-de-açúcar. Esta coleta foi realizada nas 2 plantas vizinhas às plantas marcadas, localizadas fora do campo de visada do sensor, de forma a não alterar a estrutura do dossel das plantas avaliadas espectralmente. Após a retirada das folhas, destacou-se o seu terço

médio (Figura 5), excluindo-se as nervuras (RIPOLI, 2007), e, então, estas foram enviadas ao laboratório para a determinação do teor de nitrogênio. A determinação do TFN foi obtida utilizando a metodologia semi-micro Kjeldahl, método que determina o teor do nutriente de interesse em extratos obtidos por digestão sulfúrica realizada (MALAVOLTA et al., 1997)

Para a obtenção da produtividade final de cada parcela, o experimento foi colhido manualmente, sem queima, em setembro de 2015. A cana de cada parcela foi organizada em feixes, os quais foram pesados separadamente, utilizando-se uma célula de carga instalada em uma carregadora de cana (Figura 6).

Figura 5. Terço médio da “folha +1” destacado para análise do TFN.

Figura 6. Aferição de massa das parcelas, utilizando célula de carga instalada em carregadora de cana.

3.3. Análise dos dados

3.3.1. Análise univariada dos dados de produtividade, altura, TFN e regiões espectrais

Para possibilitar a análise univariada dos dados hiperespectrais, primeiramente calculou-se a reflectância média das regiões espectrais do azul, verde, vermelho, *red-edge* e infravermelho próximo. Como referência para o cálculo destas faixas espectrais, foram utilizadas as bandas espectrais do sensor REIS (*RapidEye Earth Imaging System*) do satélite *RapidEye*, o qual apresenta a banda do azul com sensibilidade de 440 a 510 nm, banda do verde de 520 a 590 nm, banda do vermelho de 630 a 690 nm, banda do *red-edge* de 690 a 730 nm e banda do infravermelho próximo de 760 a 880 nm.

Em seguida, para os conjuntos de dados obtidos durante o desenvolvimento da cultura (altura, TFN e dados espectrais), ou seja, informações arrecadadas nas 7 primeiras coletas, conforme apresentado na Tabela 1, foi calculada a estatística descritiva e avaliada a sua normalidade por meio do teste de *Shapiro-Wilk*. Os conjuntos de dados que não apresentaram distribuição normal foram normalizados, utilizando a transformação de Box-Cox (BOX; COX, 1964) com o intuito de possibilitar a aplicação de testes de estatística paramétrica.

A análise de variância (ANOVA) e o teste *Tukey* foram aplicados sobre os dados de produtividade final para comprovação do efeito da aplicação das diferentes doses de adubação nitrogenada sobre a cultura da cana e, conseqüentemente, a avaliação da efetividade do experimento em atribuir variabilidade às parcelas experimentais. As mesmas análises foram realizadas sobre os demais parâmetros culturais e as regiões espectrais, os quais foram avaliados mensalmente, a fim de identificar a habilidade de cada variável como meio de diagnosticar as doses aplicadas de N.

Para um melhor entendimento da resposta da cultura aos tratamentos aplicados, também foram realizadas análises de regressões testando a significância do comportamento linear e quadrático de cada variável e o cálculo do coeficiente de correlação linear de Pearson para avaliar o grau de associação entre as variáveis.

Todas as análises foram conduzidas com o suplemento de análises estatísticas para Microsoft Excel, desenvolvido em plataforma R, denominado AcionStat (EstatCamp, São Carlos, SP, Brasil)

3.3.2. Avaliação qualitativa dos espectros por análise descritiva e análise de componentes principais

Para auxiliar na compreensão da resposta dos espectros em relação à dose de N aplicada, foram selecionadas as coletas que tiveram resposta significativa aos tratamentos, de acordo com a ANOVA. Os espectros de cada tratamento foram submetidos à análise descritiva, a qual avaliou, de maneira visual, a intensidade, a forma e as feições de absorção da curva espectral. A análise das feições de absorção foram realizadas utilizando a técnica da remoção do contínuo. Esta técnica consiste em remover as feições contínuas dos espectros, de forma a isolar bandas de absorção

particulares dos espectros de reflectância, permitindo assim qualificar a análise espectral (CLARK; ROUGH, 1984).

Para a análise exploratória multivariada dos espectros, objetivando identificar possíveis agrupamentos de amostras, sem incluir os demais parâmetros da cultura, aplicou-se a ACP. Esta análise foi empregada sobre os conjuntos de curvas espectrais obtidas em cada uma das 7 coletas (conjunto de 28 espectros) e também agrupando todos os dados espectrais coletados (conjunto de 196 espectros). Conforme já mencionado, foi avaliado o intervalo de 400 a 900 nm das curvas espectrais coletadas devido a presença de ruído.

As análises foram executadas utilizando o software Unscrambler 9.7 (CAMO AS, Trondheim, Noruega), sendo executadas para um número máximo de 10 componentes principais. Os valores de peso (*scores* ou autovalores) e autovetores (*loadings*) de cada componente principal, assim como a variância explicada por cada componente principal foram obtidos e transferidos ao software Microsoft Excel para construção dos gráficos.

A fim de facilitar a interpretação da ACP em função do TFN de cada parcela, foi estabelecida a classificação dos teores foliares de nitrogênio em 3 grupos: baixo, médio e alto. Para tal, adotou-se o método de análise de agrupamento K-médias, com similaridade entre grupos baseada por distância euclidiana. Este processamento também foi realizado no suplemento estatístico do software Microsoft Excel, ActionStat (EstatCamp, São Carlos, SP, Brasil).

3.3.3. Avaliações quantitativas dos espectros para predição do TFN

Avaliações quantitativas dos dados espectrais para predição do atributo de interesse foram realizadas por diferentes metodologias, as quais foram aplicadas a cada uma das 7 coletas de dados realizadas por este trabalho, assim como para o conjunto de dados formado pelo agrupamento de todos os espectros.

A primeira avaliação quantitativa do espectro foi realizada pelo método PLSR, método já bastante utilizado em quimiometria e que, conforme já discutido no tópico 2.5, consiste em relacionar os valores reais do atributo a ser predito com todos os dados espectrais (curva espectral) coletada pelo sensor. Este método utiliza todas as variáveis do espectro coletado para obtenção de sucessivas variáveis latentes (VLs), as quais maximizam a covariância entre as variáveis de predição (espectros) e de resposta (parâmetro de interesse).

Em seguida, foram selecionados e replicados 4 Índices de Vegetação (IVs) e uma regressão múltipla, todos citados pela literatura com potencial para predição do teor foliar de nitrogênio. Os IVs foram replicados juntamente com a regressão múltipla sobre os dados obtidos, de modo a verificar o seu desempenho no conjunto de dados deste trabalho. Valendo-se das equações e comprimentos de onda dos IVs selecionados, foram calculados os seus valores para os espectros de cada uma das parcelas. Tais valores foram comparados com o respectivo TFN de cada parcela e, através de regressões lineares simples, foram calibrados e validados novos modelos para cada um dos IVs.

Já para o modelo de regressão linear múltipla selecionado na literatura, foi avaliado a sua replicação sobre os conjuntos de dados de cada uma das coletas espectrais e de TFN. Ademais,

utilizou-se os comprimentos de onda propostos por tal equação, para calibração e validação de um novo modelo de regressão múltipla.

Em um último momento, semelhante a Stroppiana et al. (2009) e Müller et al. (2008), aplicou-se a técnica de sPLS associada à de *Stepwise* (referida neste trabalho como sPLS + *Stepwise*) para a seleção das melhores variáveis espectrais correlacionáveis com o TFN e, com esta informação, foram propostas regressões múltiplas para cada uma das coletas, assim como foram criados novos IVs a partir de diferentes combinações entre as variáveis selecionadas.

3.3.3.1. Determinação do TFN por PLSR

O PLSR foi o primeiro método utilizado para relacionar os espectros com os teores foliares de nitrogênio obtidos de análises convencionais de laboratório. Modelos de regressão foram gerados e validados para dados obtidos de cada uma das 7 coletas de campo.

As calibrações foram realizadas com 54% dos dados (15 parcelas) e os modelos validados sobre os demais 46% (13 parcelas); portanto, a validação empregada foi cruzada e externa. Os conjuntos de calibração e validação foram escolhidos em função do TFN das parcelas, de modo que ambos não apresentassem valores muito divergentes entre si, evitando agrupamentos que comprometessem a variabilidade dos dados.

Conforme sugerido por Milagres et al. (2013), o número de VLs utilizadas para calibração dos modelos foi padronizado para permitir a comparação dos modelos criados para cada uma das coletas. Desta forma, escolheu-se gerar os modelos com 3 VLs, já que esta quantidade permitiu, de maneira geral, um baixo erro de predição na validação. A manipulação dos dados e a geração dos modelos foram realizadas no software Unscrambler 9.7 (CAMO AS, Trondheim, Noruega). Tanto o cálculo das figuras de mérito das regressões quanto a construção dos gráficos foram realizados em planilhas do Excel.

Para avaliação dos modelos, as figuras de méritos observadas foram o R^2 , o RMSE, o RE e a RPD; todas avaliadas sobre a calibração e a validação cruzada. A RPD é obtida a partir da razão entre o desvio padrão dos valores de referência e o RMSE da regressão. Este é um parâmetro utilizado para medir a eficiência de predição do modelo e, neste trabalho, terão os seus valores interpretados conforme Chang et al. (2001).

3.3.3.2. Determinação do TFN por índices de vegetação citados na literatura

Com o intuito de avaliar algumas combinações espectrais já citadas pela literatura como promissoras para predição do TFN da cana-de-açúcar, 4 IVs foram selecionados, bem como uma regressão múltipla (Tabela 2).

Tabela 2. Índices de vegetação utilizados e as suas respectivas informações sobre: equação e bandas espectrais, o sensor utilizado no trabalho e a citação da fonte bibliográfica.

IVs	Sensor	Equação ¹	Fonte
ISR	Crop Circle, ACS – 430	B590 / B880	Amaral e Molin (2014)
NDRE	FieldSpec 3	$(B780 - B730) / (B780 + B730)$	Martins (2016)
NDI	FieldSpec 3	$(B750 - B700) / (B750 + B700)$	Miohokasap et al. (2012)
RSI	FieldSpec 3	B724 / B700	Miohokasap et al. (2012)
Regressão múltipla	FieldSpec 3	$Y = 53,32 + 227,09 * B710 - 350,54 * B720$	Barros (2016)

¹Nas equações, valor numérico precedido da letra B representa o comprimento de onda utilizado no modelo.

O cálculo dos índices foi realizado para cada um dos espectros coletados, utilizando-se das equações e comprimentos de onda apresentados na Tabela 2. Modelos de regressão linear foram gerados com 54% dos dados (15 parcelas) e validados sobre os demais (46% - 13 parcelas) para cada uma das coletas realizadas. Os mesmos conjuntos de calibração e validação foram usados na etapa anterior.

Já para o modelo de regressão linear múltipla, foi avaliado a sua replicação sobre os conjuntos de dados completos (28 parcelas) de cada uma das coletas. Ademais, também utilizou-se os 2 comprimentos de onda propostos por tal equação (710 e 720 nm), para calibração e validação de um novo modelo de regressão linear múltipla.

Todas as regressões foram avaliadas pelos seus desempenhos de R², o RMSE, o RE e a RPD.

3.3.3.3. Estimativa do TFN utilizando seleção de variáveis (sPLS + *Stepwise*) e regressão linear múltipla

Além da seleção de variáveis por sPLS + *Stepwise*, e com o intuito de comparar resultados, foi observado o coeficiente de correlação de Pearson entre o fator de reflectância de cada um dos comprimentos de onda e o TFN. Esta análise foi realizada para os conjuntos de dados das coletas e para todos os dados agrupados. Após o cálculo desta medida descritiva de correlação, selecionou-se as 10 variáveis espectrais que tivessem maior correlação com o TFN.

De maneira semelhante ao cálculo do coeficiente de correlação, a seleção de variáveis por sPLS + *Stepwise* foi também aplicada aos dados de cada coleta (conjuntos de espectros e TFN das 28 parcelas) e a todos os dados agrupados. Com os coeficientes gerados pelo sPLS, os 10 melhores comprimentos de onda foram selecionados para predição do TFN em cada coleta. Estes 10 comprimentos de onda foram submetidos à análise de *Stepwise*, a qual apurou a seleção de dados, selecionando as variáveis mais significativas para a predição do TFN. Para esta análise, utilizou-se o critério de informação de Akaike (AIC), que leva em consideração qual é a penalização dos

parâmetros estatísticos do modelo de regressão em relação à inserção ou exclusão de mais de uma variável preditora (ESTES et al., 2008). Este método foi aplicado utilizando o pacote de análises sPLS, desenvolvido para o software estatístico R (CHUNG; CHUN, 2012).

Os comprimentos de onda selecionados foram submetidos à regressão linear múltipla utilizando o software Excel. As calibrações foram realizadas com 54% dos dados (15 parcelas) e o modelo gerado foi validado nos demais 46% (13 parcelas), valendo-se dos mesmos conjuntos de calibração e validação empregados nas etapas anteriores. As figuras de mérito avaliadas foram o R^2 , o RMSE, o RE e a RPD.

3.3.3.4. Estimativa do TFN por seleção de variáveis e os índices de vegetação IRS e IDN

Devido a alta quantidade de IVs a serem testados nesta etapa, esta análise foi aplicada apenas aos dados da coleta 3 (cana aos 144 DAC), que apresentaram resultados de predição do TFN mais expressivos com os métodos já citados. Utilizando-se os dados espectrais obtidos nesta coleta e a seleção de variáveis espectrais (sPLS + *Stepwise*), mencionada no tópico anterior, novos IVs foram gerados a partir de diferentes combinações destes comprimentos de onda.

Os 6 comprimentos de onda promissores para predição do TFN - neste estágio de desenvolvimento da cultura - foram combinados aos pares, empregando fórmulas do Índice de Vegetação por Diferença Normalizada (IDN) (Equação 1) e do Índice de Vegetação por Razão Simples (IRS) (Equação 2). No total, foram avaliadas 34 diferentes combinações destes 6 comprimentos de onda específicos.

$$IDN = (\lambda_1 - \lambda_2) / (\lambda_1 + \lambda_2) \quad (1)$$

$$ISR = (\lambda_1 / \lambda_2) \quad (2)$$

Nas equações 1 e 2, as variáveis λ_1 e λ_2 foram um dos 6 comprimentos diferentes selecionados pelo método de sPLS + *Stepwise*. Os novos IVs propostos foram submetidos à Regressão Linear Simples, utilizando o software Excel. As calibrações dos modelos de regressão foram realizadas com 54% dos dados (15 parcelas) e o modelo gerado foi validado nos demais 46% (13 parcelas), aproveitando os mesmos conjuntos de calibração e validação operados nas etapas anteriores. As figuras de mérito avaliadas das regressões foram o R^2 , o RMSE, o RE e a RPD.

4. RESULTADOS E DISCUSSÃO

4.1. Análise exploratória dos dados de altura, TFN, produtividade e regiões espectrais

Em um primeiro momento, para a avaliação da distribuição dos dados, foi realizada a estatística decritiva e a aplicação do teste de normalidade de Shapiro-Wilk aos dados de altura, TFN e espectro, obtidos em cada uma das coletas, e também aos dados de produtividade coletados ao final do safra da cultura (Apêndice 1).

O teste de normalidade identificou que a distribuição normal não se adequou: aos dados espectrais da região do azul, verde e *red-edge* da coleta 2; à região do vermelho das coletas 3 e 4; e às regiões do azul, verde, vermelho e *red-edge* da coleta 6. Desta forma, para a realização das análises subsequentes utilizando estas regiões espectrais, tais dados foram submetidos à transformação de *Box Cox* (BOX; COX, 1964), conforme apresentado no Apêndice 2. O conjunto de dados da região espectral do verde da coleta 2, mesmo com a transformação aplicada, não apresentou distribuição normal, sendo assim, excluído da análise de variância (ANOVA) e análise de correlação.

A distribuição dos dados também foi apresentada por meio de gráficos de *boxplot* (Figura 7). O *boxplot* é formado pelo primeiro e terceiro quartil e pela mediana dos conjuntos de dados. As hastes inferiores e superiores se estendem, respectivamente, do quartil inferior até o menor valor, e do quartil superior até o valor máximo do conjunto de dados. Na Figura 7, o *boxplot* do TFN (Figura 7A), a altura (Figura 7B) e as regiões espectrais do azul (Figura 7C), do verde (Figura 7D), do vermelho (Figura 7E), do *red-edge* (Figura 7F) e do infravermelho próximo (Figura 7G) foram apresentados para cada uma das coletas, permitindo assim a análise temporal destas variáveis ao longo do desenvolvimento da cultura.

Para a interpretação da variação do TFN ao longo do desenvolvimento da cana na safra avaliada, vale lembrar que o corte da safra anterior foi realizado em meados de outubro, sendo assim, até os 150 DAC (meados de março) a cultura se encontrava dentro do período úmido do ano.

Figura 7. Gráficos *boxplot* mostrando a evolução do TFN, a altura e as regiões espectrais ao longo do desenvolvimento da cultura na safra avaliada. Os gráficos apresentados se referem ao TFN (A), à altura (B), e à região espectral do azul (C), do verde (D), do vermelho (E), do *red-edge* (F) e do infravermelho próximo (G).

Avaliando a Figura 7A, pode-se observar que a maior concentração de N na folha se deu aos 67 DAC (coleta 1), com mediana em torno de 17 g kg^{-1} . Já na segunda coleta (99 DAC), o TFN reduziu acentuadamente, passando a apresentar mediana aproximada de 11 g kg^{-1} . O TFN

observado nas demais coletas não apresentou oscilação acentuada como a observada nas duas primeiras (mediana oscilando entre 12 e 15 g kg⁻¹). Segundo Vitti (2003) e Pennati (2013), a maior absorção de N pela cana-de-açúcar ocorre entre os meses de outubro e março, quando há disponibilidade de água e de energia luminosa, sendo que o pico de absorção deste nutriente se dá nos primeiros 90 dias desta cultura. Sendo assim, esperava-se um maior TFN nas 2 primeiras coletas, o que não foi observado para a coleta 2 (aos 99 DAC). A queda acentuada de TFN nesta coleta pode ser explicada pela baixa precipitação ocorrida neste mês (janeiro/15) (Apêndice 3), uma vez que se apresentou precipitação de apenas 100 mm, muito inferior aos 230 mm de chuva esperados para o mês, segundo a sua média histórica, e mais de 150 mm a menos que a precipitação observada para o mês de dezembro/14, mês marcado por alto TFN.

O aumento da altura da cana está relacionada à expansão de seus entre-nós e, conseqüentemente, ao ganho de biomassa na parte aérea da planta. Na Figura 6B, é possível observar que, a cada coleta, a cultura apresentou ganho de altura, com este comportamento estendendo-se até a última coleta de campo (255 DAC). Assim, os dados de altura observados indicam que a cultura avaliada incrementou a sua biomassa até os 255 DAC.

Analisando visualmente o comportamento das regiões espectrais na Figura 7C, D, E, F e G, constata-se que estas 5 regiões espectrais exibiram 2 padrões de comportamento distintos ao longo do desenvolvimento da cana (representados pelas setas azuis nas respectivas figuras). O primeiro comportamento, observado para as regiões do azul e do vermelho, foi marcado por uma muito baixa oscilação do fator de reflectância, constatando-se também uma leve tendência descendente, à medida que a cultura se desenvolvia no campo. Já no segundo comportamento, observado para as regiões do verde, *red-edge* e infravermelho próximo, observa-se que a mediana de seu fator de reflectância ascendeu até 144 DAC, seguida de uma ligeira queda em 164 DAC, retomando o seu crescimento aos 200 DAC; a partir de então, iniciou-se o comportamento descendente até 255 DAC. No entanto, apesar de o comportamento descrito ser semelhante para estas 3 regiões (verde, *red-edge* e infravermelho próximo), o verde e o *red-edge* apresentam-se mais próximos, uma vez que ambos manifestaram uma menor oscilação temporal.

É consenso que o comportamento espectral da vegetação na região do azul e vermelho é controlado pela presença de clorofila e carotenóides na folha, sendo que a absorção da energia radiante nesta região aumenta, à proporção que se aumenta o conteúdo foliar de clorofila (TAGEEVA et al., 1960), permitindo também relacionar as propriedades espectrais à atividade fotossintética da planta (MULLA, 2013). Assim, o comportamento de fator de reflectância levemente descendente, observado para estas regiões espectrais, possibilitam inferir que a cultura da cana esteve com atividade fotossintética constante ao longo de seu ciclo no campo, o que corrobora com o desenvolvimento temporal de sua altura, o que pode ser percebido na Figura 7B.

Embora as feições de absorção da clorofila estejam situadas na região do azul e na região do vermelho, a reflectância na região do verde também é controlada pela presença de pigmentos na folha, aumentando a sua absorção, à medida que se aumenta o número de pigmentos (JENSEN, 2009). Já na região do infravermelho próximo, a sua reflectância é resultado da interação da energia incidente com a estrutura do mesófilo foliar e, em dosséis de vegetação, também ela é influenciada

pelo efeito da Reflectância Aditiva, fenômeno o qual leva ao aumento da reflectância (incremento não linear), ao passo que se aumenta o número de camadas de folhas (SOLARI, 2006; PONZONI et al., 2012). Desta maneira, analisando a proximidade de comportamento para as regiões do verde, *red-edge* e infravermelho próximo (Figura 7D, F e G), não era esperado que a região do verde apresentasse esta relação temporal com a região do infravermelho próximo, uma vez que os fatores os quais controlam a reflectância da vegetação em ambas as regiões são diferentes. Assim, para um melhor entendimento do comportamento espectro-temporal da cana-de-açúcar, mais estudos serão necessários.

O fenômeno da Reflectância Aditiva – relacionado à região espectral do infravermelho próximo – também está relacionado à saturação espectral desta região ocorrida com o aumento da biomassa do dossel de vegetação analisado, já que o incremento da reflectância com a adição de camadas de folhas não é linear, ou seja, apresenta acréscimos sempre menores, à medida que se aumenta o número de camadas de folhas (THENKABAIL et al., 2000; PONZONI et al., 2012). Analisando o comportamento temporal da região do infravermelho próximo (Figura 7G), observa-se a estabilização da reflectância entre a coleta 2 e 3, referentes a 99 e 144 DAC, respectivamente. Esta estabilização, em paralelo ao constante aumento da altura do dossel de planta (indicando ganho de biomassa), poderia indicar a saturação desta região espectral.

Portz et al. (2012a) levantam em seu trabalho que é uma característica da cana-de-açúcar o aumento de biomassa em função de seu ganho de altura e não pelo desenvolvimento de novas folhas, o que poderia acarretar na estabilização da reflectância do infravermelho próximo, não pela saturação ocasionada pela alta quantidade de camadas de folhas, mas sim pela estabilização de seu número. Na Figura 2, constata-se que entre as coletas 2 e 3 o dossel de plantas das parcelas experimentais se fechou, deixando de apresentar as “manchas” de palhada nas imagens. A interpretação das imagens é um indicativo de que o Índice de Área Foliar (IAF) do dossel de plantas tenha se estabilizado neste momento, o que justifica a estabilização da reflectância do infravermelho próximo.

De todas as formas, o observado pelo presente trabalho corrobora com o verificado por Portz et al. (2012a) e Portz et al. (2012b), em que há estabilização do fator de reflectância do infravermelho próximo, à medida que se avalia a resposta espectral do dossel de cana-de-açúcar com maior biomassa na parte aérea. Este comportamento deve ser levado em consideração para a interpretação dos Índices de Vegetação (IVs) que utilizam esta região do espectro, uma vez que a saturação é uma das principais limitações do uso de IVs baseados na região do infravermelho próximo (TODD et al. 1998; THENKABAIL et al., 2000).

Ainda analisando o comportamento da região do infravermelho próximo (Figura 7G), percebe-se também uma leve redução do fator de reflectância nesta região nas últimas coletas (cultura com 228 e 255 DAC), sendo que esta redução pode estar associada à redução natural do IAF da cana observado na segunda metade de seu ciclo de desenvolvimento. Santos et al. (2009) observaram em seus estudos que a partir dos 220 DAC a cana apresentou IAF decrescente.

Na Tabela 3, estão apresentados os coeficientes de correlação linear de Pearson entre todas as variáveis avaliadas (TFN, altura, produtividade final e regiões espectrais) para cada uma das

coletas realizadas. Os coeficientes de correlações foram interpretadas conforme Santos (2007), a qual classifica valores (positivos ou negativos), entre 0,8 e 1,0, como correlações fortes, entre 0,5 e 0,79 como correlações moderadas e inferiores a 0,5 como fracas.

Tabela 3. Correlação entre os conjuntos de dados de altura, TFN e regiões espectrais (azul, verde, vermelho, *red-edge* e infravermelho próximo) e produtividade final.

(continua)

Coeficiente de correlação linear de Pearson (r)								
----- 67 DAC (Coleta 1) -----								
	TFN	Altura	Produtiv.	Azul	Verde	Vermelho ⁽¹⁾	<i>Red-edge</i>	Infrav. próx
TFN	1,00	ns	0,39	ns	ns	ns	ns	ns
Altura	ns	1,00	ns	ns	ns	ns	ns	0,39
Produtividade	0,39	ns	1,00	ns	ns	ns	ns	-0,42
Azul	ns	ns	ns	1,00	0,97	0,90	0,93	ns
Verde	ns	ns	ns	0,97	1,00	0,82	0,99	0,50
Vermelho ⁽¹⁾	ns	ns	ns	0,90	0,82	1,00	0,77	ns
<i>Red-edge</i>	ns	ns	ns	0,93	0,99	0,77	1,00	0,58
Infrav. Próx	ns	0,39	-0,42	ns	0,50	ns	0,58	1,00
----- 99 DAC (Coleta 2) -----								
	TFN	Altura	Produtiv.	Azul ⁽¹⁾	Verde ⁽²⁾	Vermelho	<i>Red-edge</i> ⁽¹⁾	Infrav. próx
TFN	1,00	ns	0,39	ns	-	ns	ns	ns
Altura	ns	1,00	0,42	ns	-	-0,45	ns	ns
Produtividade	0,39	0,42	1,00	ns	-	ns	ns	ns
Azul ⁽¹⁾	ns	Ns	ns	1,00	-	0,95	0,98	0,66
Verde ⁽²⁾	-	-	-	-	-	-	-	-
Vermelho	ns	-0,45	ns	0,95	-	1,00	0,94	0,43
<i>Red-edge</i> ⁽¹⁾	ns	Ns	ns	0,98	-	0,94	1,00	0,67
Infrav. Próx	ns	Ns	ns	0,66	-	0,43	0,67	1,00
----- 144 DAC (Coleta 3) -----								
	TFN	Altura	Produtiv.	Azul	Verde	Vermelho ⁽¹⁾	<i>Red-edge</i>	Infrav. próx
TFN	1,00	0,56	ns	ns	-0,42	-0,56	ns	0,62
Altura	0,56	1,00	ns	-0,42	-0,49	-0,58	-0,47	0,44
Produtividade	0,52	Ns	1,00	ns	ns	-0,69	ns	0,75
Azul	ns	-0,42	ns	1,00	0,94	0,82	0,92	ns
Verde	-0,42	-0,49	ns	0,94	1,00	0,77	0,98	ns
Vermelho ⁽¹⁾	-0,56	-0,58	ns	0,82	0,77	1,00	0,74	-0,55
<i>Red-edge</i>	ns	-0,47	ns	0,92	0,98	0,74	1,00	ns
Infrav. Próx	0,62	0,44	0,47	ns	ns	-0,55	ns	1,00
----- 164 DAC (Coleta 4) -----								
	TFN	Altura	Produtiv.	Azul	Verde	Vermelho ⁽¹⁾	<i>Red-edge</i>	Infrav. próx
TFN	1,00	Ns	0,48	ns	ns	-0,48	ns	0,47
Altura	ns	1,00	0,63	ns	ns	-0,40	ns	0,48
Produtividade	0,48	0,63	1,00	ns	ns	-0,63	-0,41	0,65
Azul	ns	ns	ns	1,00	0,98	0,73	0,92	ns
Verde	ns	ns	ns	0,98	1,00	0,74	0,97	ns
Vermelho ⁽¹⁾	-0,48	-0,40	-0,63	0,73	0,74	1,00	0,83	-0,81
<i>Red-edge</i>	ns	ns	-0,41	0,92	0,97	0,83	1,00	-0,41
Infrav. Próx	0,47	0,48	0,65	ns	ns	-0,81	-0,41	1,00

Tabela 3. Correlação entre os conjuntos de dados de altura, TFN e regiões espectrais (azul, verde, vermelho, *red-edge* e infravermelho próximo) e produtividade final.

(conclusão)

Coeficiente de correlação linear de Pearson (r)								
----- 200 DAC (Coleta 5) -----								
	TFN	Altura	Produtiv.	Azul	Verde	Vermelho	<i>Red-edge</i>	Infrav. próx
TFN	1,00	ns	ns	ns	ns	-0,49	ns	ns
Altura	ns	1,00	0,79	ns	ns	Ns	ns	0,46
Produtividade	ns	0,79	1,00	ns	ns	Ns	ns	0,61
Azul	ns	ns	ns	1,00	0,99	0,90	0,98	0,87
Verde	ns	ns	ns	0,99	1,00	0,89	0,99	0,87
Vermelho	-0,49	ns	ns	0,90	0,89	1,00	0,90	0,66
<i>Red-edge</i>	ns	ns	ns	0,98	0,99	0,90	1,00	0,90
Infrav. Próx	ns	0,46	0,61	0,87	0,87	0,66	0,90	1,00
----- 228 DAC (Coleta 6) -----								
	TFN	Altura	Produtiv.	Azul ⁽¹⁾	Verde ⁽¹⁾	Vermelho ⁽¹⁾	<i>Red-edge</i> ⁽¹⁾	Infrav. próx
TFN	1,00	ns	ns	ns	ns	Ns	ns	ns
Altura	ns	1,00	0,83	-0,40	-0,43	-0,52	-0,42	ns
Produtividade	ns	0,83	1,00	-0,58	-0,61	-0,69	-0,61	-0,38
Azul ⁽¹⁾	ns	-0,40	-0,58	1,00	0,99	0,97	0,99	0,93
Verde ⁽¹⁾	ns	-0,43	-0,61	0,99	1,00	0,97	1,00	0,93
Vermelho ⁽¹⁾	ns	-0,52	-0,69	0,97	0,97	1,00	0,98	0,86
<i>Red-edge</i> ⁽¹⁾	ns	-0,42	-0,61	0,99	1,00	0,98	1,00	0,94
Infravermelho	ns	ns	-0,38	0,93	0,93	0,86	0,94	1,00
----- 255 DAC (Coleta 7) -----								
	TFN	Altura	Produtiv.	Azul	Verde	Vermelho	<i>Red-edge</i>	Infrav. próx
TFN	1,00	ns	ns	ns	ns	Ns	ns	ns
Altura	ns	1,00	0,83	ns	ns	-0,40	ns	0,63
Produtividade	ns	0,83	1,00	ns	ns	-0,44	ns	0,53
Azul	ns	ns	ns	1,00	0,97	0,83	0,97	0,71
Verde	ns	ns	ns	0,97	1,00	0,87	1,00	0,63
Vermelho	ns	-0,40	-0,44	0,83	0,87	1,00	0,86	ns
<i>Red-edge</i>	ns	ns	ns	0,97	1,00	0,86	1,00	0,67
Infrav. próx	ns	0,63	0,53	0,71	0,63	Ns	0,67	1,00

Valores em negrito indicam correlação significativa com nível de significância inferior a 0,05;

⁽¹⁾ Análise de correlação aplicada sobre os dados normalizados após serem submetidos à transformação de *Box Cox*;

⁽²⁾ Análise de correlação não aplicada, devido à impossibilidade de normalização do conjunto de dados.

Observa-se na Tabela 3 que o TFN apenas se relacionou com alguma região espectral nas coletas 3, 4 e 5 (respectivamente 144, 164 e 200 DAC), com destaque para a coleta 3, a qual apresentou maior número de regiões espectrais com correlação significativa e maiores valores de coeficiente de correlação. A ausência de relação entre espectro e TFN nas 2 primeiras coletas pode estar associada à influência do solo/palhada na resposta espectral do dossel de plantas, uma vez que o dossel da cana-de-açúcar ainda não havia se fechado neste momento (Figura 2) e o campo de visada do sensor poderia estar englobando a reposta espectral das entrelinhas.

Já a ausência de relação entre TFN e os dados espectrais adquiridos nas 2 últimas coletas (respectivamente 228 e 255 DAC) e a fraca relação observada na coleta 5 (200 DAC) podem estar

associadas à diluição da concentração do N nas folhas. Conforme mencionado por Jarrell e Beverly (1981), a concentração dos nutrientes é diluída com o maior desenvolvimento da planta nos tratamentos que recebem altas doses de fertilizantes nitrogenados.

Ainda analisando a Tabela 3, destaca-se também que quando o TFN se correlaciona com as regiões do visível, esta correlação se mostrou inversa; e quando correlacionado com o infravermelho próximo (apenas coleta 3 e 4), esta correlação se mostrou direta. Estes comportamentos nas correlações já eram esperados, pois eles concordam com os efeitos da adubação nitrogenada na planta, (da reflectância no visível) e uma maior produção de biomassa (aumento da reflectância no infravermelho próximo). Mulla (2013) explica que a região espectral do visível é caracterizada por sua relação inversa com a radiação absorvida pelos pigmentos e, na região do infravermelho próximo, pela alta reflectância ocasionada pela densidade de folhas e pelos efeitos da estrutura do dossel de plantas.

Apesar de o TFN haver se correlacionado com as regiões espectrais do visível em um maior número de coletas (coletas 3, 4 e 5), quando comparadas ao número de vezes que ele se correlacionou com a região do infravermelho próximo (apenas coleta 3 e 4), os valores dos coeficientes de correlação entre TFN e espectro visível se apresentaram de maneira geral fracas (menores que 0,5), sendo a única exceção com a região do vermelho na coleta 3, a qual apresentou correlação moderada (r de -0,56).

Na coleta 3, momento em que a região do infravermelho próximo apresenta correlação significativa com o TFN, este também se correlaciona com a altura, variável que representa o ganho de biomassa da cultura. Esta observação permite cogitar que as correlações entre TFN e infravermelho próximo podem ter ocorrido de maneira indireta, uma vez que esta região espectral relaciona-se melhor com os aspectos de biomassa do dossel de plantas (MULLA, 2013).

Observa-se, ainda na Tabela 3, que em nenhuma das coletas a região espectral do *red-edge* e do azul apresentaram correlação significativa com o TFN. O *red-edge* apenas apresentou correlação significativa com a altura da cana nas coletas 3 e 6. Esta observação corrobora com Heege et al., (2008), os quais afirmam que o *red-edge* apresenta mais informações da biomassa dos dosséis de vegetação em comparação com as demais regiões do espectro eletromagnético.

Comenta-se ainda que as regiões do verde e do *red-edge* apresentaram alto grau de associação, sendo que nenhum de seus coeficientes de correlação foram menores que 0,97, o que comprova que o comportamento temporal semelhante destas regiões, algo visualizado nas Figuras 7D e F.

Em um último momento, destaca-se que, apesar das correlações entre TFN e regiões espectrais oscilarem entre moderadas e fracas, variando (em módulo) entre 0,42 e 0,62, quando significativas, esta é uma análise que não explora todo o potencial de informação do espectro eletromagnético, sendo para tal, necessárias análises mais aprofundadas, as quais serão apresentadas a partir do tópico 4.4.

4.2. Resposta da produtividade, altura, TFN e regiões espectrais quanto a dose de nitrogênio aplicada

A ANOVA realizada com os dados de produtividade final das parcelas experimentais comprovou o efeito dos tratamentos aplicados ao experimento. A cana respondeu linearmente em aumento de produtividade ao se ampliarem as doses de N aplicadas. Porém, estatisticamente as doses 60, 120 e 180 kg ha⁻¹ não diferiram entre si, havendo diferença significativa apenas entre a dose 0 e as doses de 120 e 180 kg ha⁻¹ (Tabela 4).

Trabalhos de diferentes autores concordam que a resposta da cana-de-açúcar ao N é variável; nem sempre esta cultura responde em produtividade às doses de N aplicadas em campo, principalmente devido à disponibilização de N por outras fontes, tais como a mineralização da matéria orgânica presente no solo e a fixação por microorganismos (FRANCO et al., 2011; AMARAL, 2014). Por outro lado, Cantarella et al. (2007) afirmam que, quando os dados dos experimentos com doses de N em cana são analisados em conjuntos, observa-se importante resposta a esse nutriente em ganho de produtividade.

Tabela 4. Média de produtividade para as diferentes doses de N aplicadas, teste *Tukey* entre doses e análise de regressão

Dose de N aplicada (kg ha ⁻¹)				Reg. linear	Reg. quadr.
0	60	120	180		
----- t ha ⁻¹ -----				---- p-valor ----	
82,46 b	92,03 ab	97,73 a	98,31 a	0,002	0,137

Médias seguidas por letras iguais (na horizontal) não se diferem estatisticamente entre si pelo teste *Tukey* a 5%.

Uma vez comprovada a resposta da cana-de-açúcar em sua produtividade final, a Tabela 5 apresenta a média das variáveis analisadas (altura, TFN e variáveis espectrais) ao longo de seu desenvolvimento – em cada coleta de campo realizada – assim como o teste *Tukey* para os parâmetros que apresentaram efeito de tratamento e a análise de regressão. A análise da resposta à dose de N aplicada das diferentes variáveis apresentadas na Tabela 5 será conduzida em 3 momentos: primeiro, analisando a resposta do TFN; em um segundo momento, será analisado a resposta da altura; e em um terceiro momento, avaliando a resposta das propriedades espectrais em função do TFN e da altura.

Tabela 5. Média de altura, TFN e regiões espectrais (azul, verde, vermelho, *red-edge* e infravermelho próximo) em função da dose de N aplicada, teste *Tukey* entre doses aplicadas de N e análise de regressão.

(continua)

Dose de N aplicada (kg ha ⁻¹)	Altura (cm)	TFN (g kg ⁻¹)	Azul (%)	Verde (%)	Vermelho (%)	<i>Red-edge</i> (%)	Infravermelho próx. (%)
----- 67 DAC (Coleta 1) -----							
0	100,80 ns	14,91 b	3,69 ns	6,89 ns	5,84 ns	12,17 ns	29,84 ns
60	99,00 ns	16,50 ab	3,48 ns	6,35 ns	5,19 ns	11,58 ns	30,62 ns
120	100,20 ns	18,06 ab	3,55 ns	6,54 ns	5,21 ns	11,27 ns	31,10 ns
180	97,65 ns	18,76 a	3,39 ns	6,19 ns	4,94 ns	10,98 ns	32,26 ns
Reg. linear (p-valor)	-	0,003	-	-	-	-	-
Reg. quadr. (p-valor)	-	0,584	-	-	-	-	-
----- 99 DAC (Coleta 2) -----							
0	167,00 ns	8,42 b	4,02* ns	7,57**	6,32 ns	13,82* ns	36,74 ns
60	172,58 ns	10,57 ab	3,97* ns	7,44**	5,45 ns	13,37* ns	42,78 ns
120	174,93 ns	10,81 ab	3,71* ns	6,97**	4,95 ns	12,53* ns	42,26 ns
180	170,43 ns	10,88 a	3,80* ns	6,98**	5,07 ns	12,61* ns	43,44 ns
Reg. linear (p-valor)	-	0,004	-	-	-	-	-
Reg. quadr. (p-valor)	-	0,384	-	-	-	-	-
----- 144 DAC (Coleta 3) -----							
0	225,75 ns	10,53 c	3,42 ns	7,01 ab	5,29* a	12,64 ns	35,69 b
60	237,88 ns	12,51 bc	3,44 ns	7,13 a	4,58* ab	12,81 ns	43,77 a
120	246,50 ns	13,83 ab	3,40 ns	6,89 ab	4,34* b	12,48 ns	46,23 a
180	246,00 ns	14,39 a	3,22 ns	6,49 b	4,10* b	11,81 ns	44,70 a
Reg. linear (p-valor)	-	< 0,001	-	0,008	< 0,001	-	< 0,001
Reg. quadr. (p-valor)	-	0,164	-	0,153	0,234	-	< 0,001
----- 164 DAC (Coleta 4) -----							
0	258,40 ns	13,57 ns	3,18 ns	6,48 ns	5,07* a	12,03 ns	33,85 b
60	264,23 ns	14,93 ns	3,09 ns	6,33 ns	4,52* ab	11,71 ns	37,00 ab
120	276,38 ns	14,59 ns	3,05 ns	6,23 ns	4,16* b	11,53 ns	39,84 a
180	270,68 ns	15,63 ns	3,01 ns	6,14 ns	4,07* b	11,34 ns	39,43 a
Reg. linear (p-valor)	-	-	-	-	0,002	-	< 0,001
Reg. quadr. (p-valor)	-	-	-	-	0,229	-	0,049
----- 200 DAC (Coleta 5) -----							
0	287,50 b	14,02 ns	2,96 ns	6,37 ns	4,57 ns	11,99 ns	37,24 b
60	296,50 ab	13,71 ns	3,42 ns	7,32 ns	5,23 ns	13,97 ns	46,33 ab
120	311,50 a	14,19 ns	3,21 ns	6,81 ns	4,70 ns	13,02 ns	45,01 ab
180	304,63 ab	14,31 ns	3,34 ns	7,04 ns	4,88 ns	13,52 ns	47,03 a
Reg. linear (p-valor)	0,010	-	-	-	-	-	0,037
Reg. quadr. (p-valor)	0,076	-	-	-	-	-	0,153

Tabela 5. Média de altura, TFN e regiões espectrais (azul, verde, vermelho, *red-edge* e infravermelho próximo) em função da dose de N aplicada, teste *Tukey* entre doses aplicadas de N e análise de regressão.

(conclusão)							
Dose de N aplicada (kg ha ⁻¹)	Altura (cm)	TFN (g kg ⁻¹)	Azul (%)	Verde (%)	Vermelho (%)	<i>Red-edge</i> (%)	Infravermelho próx. (%)
----- 228 DAC (Coleta 6) -----							
0	313,50 b	12,55 ns	3,26* ns	7,41* ns	4,81* ns	13,21* ns	39,29 ns
60	328,00 ab	12,75 ns	3,06* ns	6,81* ns	4,43* ns	12,60* ns	40,75 ns
120	337,50 a	12,47 ns	3,06* ns	6,60* ns	4,21* ns	12,13* ns	40,72 ns
180	337,75 a	12,78 ns	2,81* ns	6,09* ns	3,92* ns	11,36* ns	39,09 ns
Reg. linear (p-valor)	0,002	-	-	-	-	-	-
Reg. quadr. (p-valor)	0,134	-	-	-	-	-	-
----- 255 DAC (Coleta 7) -----							
0	337,50 b	12,06 ns	2,64 ns	6,11 ns	4,32 ns	11,68 ns	33,79 ns
60	353,38 ab	13,38 ns	2,66 ns	6,01 ns	4,10 ns	11,60 ns	36,51 ns
120	361,63 a	12,84 ns	2,60 ns	5,79 ns	3,88 ns	11,22 ns	36,84 ns
180	355,63 ab	12,36 ns	2,72 ns	6,04 ns	4,09 ns	11,70 ns	38,18 ns
Reg. linear (p-valor)	0,016	-	-	-	-	-	-
Reg. quadr. (p-valor)	0,015	-	-	-	-	-	-

Médias seguidas por letras iguais (na vertical) não se diferem estatisticamente entre si pelo teste *Tukey* a 5%; Médias seguidas pela sigla ns não apresentaram diferença significativa entre os tratamentos segundo ANOVA a 5%;

* ANOVA e teste *Tukey* aplicados sobre os dados normalizados após serem submetidos à transformação de *Box Cox*;

** ANOVA e teste *Tukey* não aplicados, devido à impossibilidade de normalização do conjunto de dados.

Observando em um primeiro momento o comportamento do TFN em relação às doses aplicadas de N, constata-se que, até os 164 DAC, o teor deste nutriente na folha aumentou conforme o aumento da dose aplicada (Tabela 5). Este comportamento foi estatisticamente significativo para as 3 primeiras coletas, quando a cultura se encontrava aos 67, 99 e 144 DAC, respectivamente, sendo que nestes 3 momentos a resposta de TFN se mostrou linear. Segundo Penatti (2013), a maior absorção de N pela cana ocorre entre outubro e março, período com disponibilidade de água e radiação solar. Vale lembrar que, no presente trabalho, o fim do período úmido (fim de março) ocorreu quando a cultura se encontrava com aproximadamente 160 DAC. Desta forma, o TFN se relacionou com a adubação aplicada apenas no período marcado por maior umidade.

A ausência de efeito de tratamento sobre o TFN a partir dos 164 DAC também pode estar relacionada ao efeito da diluição, já que a concentração dos nutrientes é diluída com o maior crescimento da planta, nos tratamentos que recebem altas doses de fertilizantes nitrogenados (JARRELL; BEVERLY, 1981).

A relação entre TFN presente na folha +1 e a adubação de N observada no presente trabalho corrobora com os resultados encontrados por Rozane et al. (2008). Estes autores avaliaram o efeito da adubação nitrogenada em folhas +1 e +3 de cana de segunda soqueira, coletadas aos 4 e 9 meses após o corte da última safra, e verificaram que em ambas as folhas e períodos de coletas a resposta do TFN foi significativa ao incremento da adubação de N.

Penatti (2013) afirma que o pico da absorção de N ocorre entre novembro e janeiro, independente da época de plantio. Vitti (2003) complementa ainda que a maior quantidade do N absorvido neste momento é armazenada nas raízes e nas folhas. Desta forma, o observado no presente experimento concorda com estes autores, uma vez que o pico de TFN foi observado aos 67 DAC (meados de dezembro).

A dinâmica de TFN observada neste trabalho permite sugerir que, apesar da oscilação temporal observada para este parâmetro (Figura 7A) – a qual, conforme mencionado, pode ser reflexo das condições de baixa umidade no momento da coleta –, a quantidade deste nutriente na folha, até os 144 DAC, acompanha a oferta deste nutriente pelo solo, uma vez que a resposta de TFN foi estatisticamente significativa às doses de N até este momento (Tabela 5). Assim, avaliando os presentes resultados, infere-se que, embora o TFN oscile temporalmente, a diagnose foliar deste nutriente, quando realizada até 144 DAC, ainda expressaria a variabilidade espacial de disponibilidade deste nutriente pelo solo.

Em um segundo momento, observando a resposta da altura em relação aos tratamentos aplicados, conclui-se que este parâmetro apresentou resposta significativa à adubação nitrogenada a partir de 200 DAC (coleta 5), estendendo esta resposta até o final do ciclo (Tabela 5). Apesar de a análise de variância indicar significância somente a partir da coleta 5, ao se avaliar a média de altura para os diferentes tratamentos, é possível deduzir que a partir de 99 DAC (coleta 2) a cultura já apresentava alturas inferiores nos tratamentos com menor dose de N aplicada.

Santos et al. (2009) relatam que o crescimento médio de altura de colmos contrasta bem com a queda na população de perfilhos, a qual ocorre entre o quarto e o sexto mês após o corte (120 e 180 DAC). Os autores ainda comentam que o comportamento natural da população de perfilhos na cana é ascender até o momento do pico desta população (por volta do quarto mês), seguido por sua redução devido à grande mortalidade de perfilhos ocasionada pela competição populacional.

Pode-se inferir a partir dos dados deste experimento que a resposta da altura (indicador de biomassa) e do TFN ocorreram de maneira diferente. Enquanto o TFN respondeu à adubação nitrogenada no período inicial do ciclo da cultura (até 144 DAC), possivelmente influenciado pela disponibilidade de água deste período e por características intrínsecas da cultura, a altura, por sua vez, só respondeu de forma significativa às doses de N no final do ciclo da cana (a partir de 200 DAC).

Finalmente, analisando a resposta das regiões espectrais em relação aos tratamentos, observa-se que espectralmente foi possível diferenciar as doses de N aplicadas apenas nas coletas 3, 4 e 5 (144, 164 e 200 DAC, respectivamente). É importante frisar que, dentre estas coletas, a única que também apresentou uma resposta estatisticamente significativa do TFN em relação às doses de N foi a coleta 3 (144 DAC). Nesta terceira coleta, foi possível diferenciar as doses de N pelo comportamento espectral do verde, vermelho e infravermelho próximo. Por outro lado, na coleta 4, as regiões espectrais significativas foram a do vermelho e infravermelho próximo e, na coleta 5, apenas a região do infravermelho próximo, ou seja, mesmo neste período, quando o espectro foi sensível às doses de N aplicadas, houve uma redução do número de regiões espectrais que responderam à dose de N aplicada conforme a cultura se desenvolvia.

Destaca-se também que nas coletas 1, 2 e 3 o TFN respondeu de forma significativa em relação às doses de N aplicadas. Em contrapartida, espectralmente esta resposta somente foi verificada nas coletas 3, 4 e 5, ou seja, houve um atraso até que a resposta espectral da cana conseguisse responder às doses de N. Amaral e Molin (2011) avaliando a cana-de-açúcar aos 60, 120 e 145 DAC (altura média de colmos de 0,2; 0,4 e 0,6 m, respectivamente) também só constatarem a diferenciação das doses de N pelos dados espectrais a partir da segunda avaliação (120 DAC). Esta mesma constatação foi verificada por Amaral e Molin (2014). Estes autores atribuem esta sensibilidade tardia da resposta espectral a um de 2 fatores, sendo eles: (i) devido à ausência de tempo suficiente para que a planta respondesse em produção de biomassa, principal parâmetro a que sensores de dosséis são sensíveis; ou (ii) devido à interferência do solo/palhada na resposta espectral, pelo fato de que nestes estágios iniciais do desenvolvimento da cultura o seu dossel de plantas ainda não está fechado.

De fato, no presente trabalho, foram observados ambos os fatores esboçados por Amaral e Molin (2014). No entanto, em relação ao primeiro fator, ressalta-se que apesar da altura – principal indicador de biomassa da cultura da cana – ainda não haver respondido às doses aplicadas na coleta 1 e 2, ela tampouco havia respondido à dose de N nas coletas 3 e 4, quando foram verificadas respostas significativas de algumas regiões espectrais. Ressalta-se ademais que o TFN respondeu às doses de N aplicadas na coleta 1, 2 e 3. Esta observação leva a pensar que a resposta espectral observada nas coletas 3 e 4 pode estar relacionada ao TFN.

Em relação ao segundo fator colocado por Amaral e Molin (2014), pode ser cogitado no presente trabalho que a presença de palhada influenciou a resposta espectral coletada pelo sensor, uma vez que o dossel de vegetação ainda não se apresentava fechado antes da coleta 3, conforme pode ser observado na Figura 2.

Ainda analisando a resposta das regiões espectrais em relação aos tratamentos, observou-se a ausência de resposta das regiões espectrais nas coletas 6 e 7 (228 e 255 DAC, respectivamente). A diminuição da resposta espectral às doses de N, à medida que a planta se desenvolve, já foi relatada por vários autores que utilizaram IVs compostos pela região do infravermelho próximo (PORTZ et al., 2012a; PORTZ et al., 2012b; AMARAL, 2014) e, segundo já mencionado, este fato pode ser explicado tanto por um possível efeito do fenômeno da Reflectância Aditiva, quanto pela estabilização do número de camadas de folhas, comportamento característico da cana-de-açúcar.

Por outro lado, observou-se no presente trabalho que as regiões do visível também deixaram de responder à dose de N. De fato, esta interrupção ocorreu antes da observada para a região do infravermelho próximo, conforme pode-se verificar na Tabela 5. Uma possível explicação para este fato pode ser a diluição da concentração do N nas folhas, à proporção que a planta se desenvolve (JARRELL; BEVERLY, 1981), o que é constatado nos dados do presente trabalho (Figura 7A e Tabela 5).

Em um último momento, nota-se, ainda na Tabela 5, que em nenhuma das coletas a região espectral do azul e do *red-edge* foram sensíveis ao responder às doses aplicadas de N. Recordar-se

ainda que estas regiões tampouco apresentaram correlação com o TFN na análise apresentada pela Tabela 3 no tópico anterior.

4.3. Avaliação qualitativa dos espectros por análise descritiva

Na Figura 8 estão apresentadas as respostas espectrais resultantes da média de cada tratamento, assim como os espectros com o contínuo removido das coletas 3, 4 e 5 (cultura aos 144, 164 e 200 DAC), momento em que a resposta espectral respondeu à dose de N aplicada de acordo com a ANOVA (Tabela 5).

Figura 8. Curvas espectrais de cada tratamento (à esquerda) e o seu respectivo espectro com o contínuo removido (à direita) para as coletas 3, 4 e 5 (cultura com 144, 164 e 200 DAC, respectivamente).

Analisando as curvas espectrais dos diferentes tratamentos (Figura 8), verifica-se que as diferenças de intensidade entre os espectros são mais sutis na região do visível e do *red-edge* (até 730 nm) em comparação às regiões do infravermelho próximo e do *red-edge* (após 730 nm). Desta forma, realizou-se a técnica da remoção do contínuo para uma avaliação descritiva mais precisa das diferenças de intensidade das regiões anteriores a 730 nm.

De maneira geral, a curva mais contrastante foi a que representa dosséis de planta os quais não receberam adubação nitrogenada (dose 0). Em todos os gráficos apresentados, a curva da dose 0 apresentou menor fator de reflectância na região do infravermelho próximo e na região do *red-edge* após 730 nm e maior fator de reflectância na região do visível (400 a 699 nm). Conforme o esperado, nota-se que, à medida que se aumentou a dose de N aplicada, houve uma tendência de aumento do fator de reflectância na região do infravermelho próximo e do *red-edge* (após 730 nm), além de uma redução na região do visível (aumento da absorção). Ponzoni et al. (2012) afirmam que a região do visível é influenciada pela quantidade de pigmentos nas folhas: quanto maior a energia absorvida pelos pigmentos, menor será o fator de reflectância nesta região do espectro. De fato, foi verificado o aumento do TFN conforme o aumento da adubação nitrogenada nas coletas 1, 2, 3 e 4 (Tabela 5). A maior presença deste nutriente possivelmente estimulou a produção de pigmentos pelas folhas de plantas que receberam mais adubação. Por sua vez, acredita-se que o aumento da reflectância na região do *red-edge* e do infravermelho próximo está relacionado ao ganho de biomassa promovido pela adubação nitrogenada a esta cultura, devido à estreita relação destas regiões do espectro com esta variável.

A análise de remoção do contínuo, apresentada na Figura 8, mostrou que nos dados do presente trabalho as feições de absorção de clorofila da cana-de-açúcar apresentaram picos de absorção em 495 e em 680 nm. Trabalhos de Breunig et al. (2007) e Monteiro et al. (2009) avaliaram espectros de trigo e feijão, respectivamente, por meio da técnica de remoção do contínuo e também encontraram picos de absorção próximos aos observados pelo presente trabalho. Por outro lado, Jensen (2009) menciona que as principais feições de absorção da clorofila estão entre 430 e 450 nm (região do azul) e entre 650 e 660 nm (região do vermelho); contudo, este autor não menciona a espécie observada, sendo possivelmente uma divergência devido à avaliação de espécies diferentes.

4.4. Avaliação qualitativa dos espectros por análise de componentes principais

A Análise de Componentes Principais (ACP) foi aplicada às curvas espectrais (de 400 a 900 nm) com o intuito de identificar possíveis formações de grupos entre espectros com comportamentos semelhantes. Esta verificação é realizada mediante a análise dos pesos (*scores*) das componentes principais (CPs) que melhor expliquem as variações dos dados espectrais, geralmente realizada por meio de gráficos de distribuição.

Para todas as coletas, dos 10 componentes utilizados na ACP realizada, apenas os 2 primeiros foram suficientes para explicar a variabilidade dos dados, sendo que ambos representaram pelo menos 99% dessa variação, conforme o apresentado pela Tabela 6.

Tabela 6. Variância explicada pela análise de componentes principais para os dados espectrais

CP	Dias Após o Corte (DAC) e coleta ⁽¹⁾								
	Geral ⁽²⁾	67 (1)	99 (2)	144 (3)	164 (4)	200 (5)	228 (6)	255 (7)	173 (8)
1	97	94	93	97	97	99	99	97	93
2	3	6	7	2	2	1	1	3	7
Total	100	100	100	99	99	100	100	100	100

⁽¹⁾ Número da coleta apresentado entre parênteses;

⁽²⁾ Análise aplicada aos dados agrupados de todas as coletas.

Na Figura 9, estão apresentados os gráficos com a distribuição das parcelas (marcada conforme a dose de N aplicada) em função dos pesos (*scores*) das componentes principais 1 e 2 obtidos de sua resposta espectral, para cada uma das coletas realizadas. Ao se analisar visualmente esta figura, constata-se que, de uma maneira geral, é difícil a identificação de agrupamentos entre parcelas de um mesmo tratamento. Apenas aos 144 DAC (coleta 3) é possível observar uma ligeira separação entre baixas e altas doses de N aplicadas ao se observar o comportamento da CP 1, em que parcelas com doses mais baixas apresentaram *scores* mais baixos (inferiores a -0,5) e parcelas com doses mais altas, *scores* mais altos (superiores a 0,5).

Figura 9. Gráficos com a distribuição das parcelas (marcada conforme a dose de N aplicada) em função dos pesos (scores) das componentes principais 1 e 2 obtidos de sua resposta espectral, para cada uma das coletas realizadas.

A dificuldade de visualização dos agrupamentos em função dos tratamentos aplicados, com uma ligeira diferenciação de doses apenas na coleta 3, reforçam os resultados da ANOVA (Tabela 5) e da análise de correlação (Tabela 3). Entre elas, a coleta 3 se destacou por apresentar um maior número de regiões espectrais com resposta significativa à dose de N aplicada, assim como maiores valores de coeficiente de correlação.

A Tabela 7 mostra as correlações entre o TFN e os scores dos CP 1 e 2. Apresentaram melhores correlações as coletas 3, 4 e 5, reafirmando a análise de correlação apresentada pela Tabela 3, na qual estas mesmas coletas foram as únicas a apresentar certo grau de associação entre as regiões espectrais avaliadas e o TFN. Ademais, novamente destacou-se a coleta 3 (144 DAC), por apresentar correlação significativa com o TFN, tanto para a CP 1, quanto para a CP 2.

Tabela 7. Correlação entre o TFN e as 2 primeiras componentes principais

CP	Geral ⁽²⁾	Dias Após o Corte (DAC) e coleta ⁽¹⁾						
		67 (1)	99 (2)	144 (3)	164 (4)	200 (5)	228 (6)	255 (7)
1	-0,23	ns	ns	0,62	0,47	ns	ns	ns
2	ns	ns	ns	-0,40	ns	-0,50	ns	ns

Valores em negrito indicam correlação significativa com nível de significância inferior a 0,05;

⁽¹⁾ Número da coleta apresentado entre parênteses;

⁽²⁾ Análise aplicada aos dados agrupados de todas as coletas.

Os gráficos com a distribuição das parcelas em função dos *scores* das CP 1 e 2 foram novamente apresentados na Figura 10; porém, nesta figura as parcelas foram marcadas conforme o seu respectivo TFN, com o intuito de verificar se essas, com teores próximos de N na folha, apresentariam resposta espectral semelhante. Além disso, foram expostas nessa figura somente as coletas que apresentaram correlação significativa entre alguma das CPs e o TFN. Os autovetores que mostram a contribuição dos valores de reflectância de cada comprimento de onda no score de cada componente principal também estão representados na Figura 10.

A classificação k-médias aplicada sobre os conjuntos de dados de TFN permitiu separá-los em 3 grupos com teores próximos entre si. As parcelas de cada grupo foram marcadas nos gráficos de dispersão apresentados na Figura 10, de forma a auxiliar na interpretação dos possíveis agrupamentos formados na ACP que tivessem relação com seu TFN. A estatística descritiva do TFN de cada agrupamento gerado pela classificação k-médias, para as diferentes coletas e para todos os dados agrupados, está apresentada no Apêndice 5.

Analisando visualmente a Figura 10, pode-se verificar que novamente a coleta 3 (144 DAC) foi a que apresentou uma melhor separação entre parcelas com baixos e altos TFNs, principalmente quando comparada aos demais gráficos de dispersão das demais coletas. Esta separação, embora discreta, ocorre tanto para os *scores* da CP 1, quanto para os da CP 2. A CP 1 agrupa parcelas com baixo TFN à esquerda do gráfico (valores menores que -0,5) e parcelas com médio e alto TFN à direita (valores superiores a -0,5). Já a CP 2 tende a apresentar parcelas com valores baixos de TFN acima do score 0,0 e com valores médios e altos de TFN abaixo de 0,0. Apesar disso, este agrupamento realizado CP 2 não se apresentou tão claro, e algumas parcelas retrataram valores médios e altos de TFN, reflexo da fraca correlação entre CP 2 e TFN (Tabela 7).

Figura 10. Gráficos com a distribuição das parcelas e os seus respectivos TFNs (classificados em baixo, médio e alto) em função dos pesos (scores) das componentes principais 1 e 2 obtidos de sua resposta espectral (à esquerda) e autovetores da análise de componentes principais (à direita), para as coletas que apresentaram correlação significativa entre o score de umas das componentes e o TFN.

A separação apenas entre baixo e alto TFN corrobora com o teste de *Tukey* apresentado nas Tabelas 4 e 5, as quais mostraram que, de forma geral, houve diferenciação na resposta aos tratamentos apenas entre doses baixas e altas.

Estes resultados indicam que a reposta espectral da cana-de-açúcar não é função apenas do TFN de seu dossel de plantas, possivelmente esta relação é indireta e se expressa apenas em alguns momentos de seu desenvolvimento (principalmente aos 144 DAC). A interpretação do espectro deve ser realizada de maneira mais dinâmica, avaliando a influência de vários fatores concomitantemente, uma vez que ele é uma análise multi-informacional. Contudo, apesar destas observações, frisa-se que a ACP é uma técnica a qual analisa todo o espectro, não estudando bandas específicas (DEMATTE et al., 2016), as quais poderiam apresentar resultados mais expressivos em resposta à dose de N aplicada e ao TFN.

4.5. Determinação do TFN por meio dos dados espectrais

A estimativa do TFN a partir dos dados espectrais foi realizada valendo-se de 4 métodos quantitativos, sendo eles: Regressão por Mínimo Quadrados Parciais (PLSR); regressão simples utilizando IVs citados na literatura; regressão linear múltipla, utilizando as bandas selecionadas por métodos de seleção de variáveis (sPLS + *Stepwise*) e regressão linear simples utilizando novos IVs construídos utilizando as bandas selecionadas pelo método de seleção de variáveis.

Os diferentes métodos foram aplicados aos dados obtidos em cada uma das coletas, assim como nos dados agrupados, contendo todas as coletas. Os resultados das predições foram avaliados conforme o desempenho das figuras de mérito R^2 , o RMSE, o RE e a RPD, da calibração e da validação.

Para a interpretação dos valores de R^2 e da RPD, utilizou-se como referência os autores Saeys et al. (2005) e Chang et al. (2001), respectivamente. Segundo os primeiros autores citados, modelos com valores de R^2 inferiores a 0,50 são considerados ruins; R^2 entre 0,50 e 0,65 indicam um modelo razoável, com a possibilidade de discriminação das altas e baixas concentrações do atributo modelado; enquanto valores de R^2 entre 0,66 e 0,86 e acima de 0,86 indicam modelos quantitativos de predição bons e excelentes, respectivamente. Por sua vez, Chang et al. (2001) mencionam que valores da RPD menores que 1,40 indicam modelos não confiáveis; valores entre 1,40 e 2,00 indicam modelos razoáveis e valores superiores a 2,00, modelos excelentes que predizem de forma acurada o atributo.

4.5.1. Determinação do TFN por PLSR

O método da PLSR utiliza todas as variáveis do espectro para obtenção de sucessivas Variáveis Latentes (VLs), de forma que estas novas variáveis maximizem a covariância entre as variáveis iniciais (diferentes comprimentos de onda dos espectros) e do parâmetro de interesse (TOBIAS, 1995; VISCARRA ROSSEL et al., 2006). Assim, embora a PLSR utilize como entrada toda a reposta espectral, que sabidamente apresenta uma grande quantidade de variáveis colineares – que, por sua vez, prejudicariam a confiabilidade dos modelos de regressões ajustados – este método consegue se desviar desta limitação, ao converter esses dados iniciais em variáveis latentes não correlacionadas.

Na Tabela 8, estão apresentados os resultados da PLSR para determinação do TFN, de acordo com os diferentes DAC da cultura. Verifica-se que, em nenhum momento, a validação dos modelos apresentou figuras de mérito indicando modelos com boas predições. Por este método, a coleta que apresentou melhor validação do modelo de predição calibrado foi a realizada ao 144 DAC. Todavia, os seus valores de R^2 e RPD apontaram um modelo razoável, ou seja, capaz de discriminar apenas altas e baixas concentrações do TFN.

Tabela 8. Figuras de mérito da calibração e validação da PLSR para predição do TFN, de acordo com os DAC da cultura

DAC e coleta ⁽¹⁾	Calibração				Validação				nVL
	R^2	RMSE (g kg ⁻¹)	RE (%)	RPD	R^2	RMSE (g kg ⁻¹)	RE (%)	RPD	
Geral ⁽²⁾	0,13	2,33	17,15	1,07	0,10	2,38	17,50	1,05	3
67 (1)	0,49	1,72	9,74	1,45	0,36	3,54	20,87	0,69	3
99 (2)	0,43	1,28	12,87	1,37	0,10	1,70	15,42	0,85	3
144 (3)	0,65	0,96	7,11	1,75	0,63	1,28	10,04	1,49	3
164 (4)	0,38	0,97	6,55	1,32	0,39	1,35	9,02	1,29	3
200 (5)	0,47	1,23	8,83	1,42	0,17	0,97	6,85	1,07	3
228 (6)	0,34	1,07	8,35	1,27	0,04	1,75	14,00	0,79	3
255 (7)	0,18	1,30	10,19	1,14	0,00	1,83	14,41	1,03	3

Valores de R^2 em negrito indicam coeficiente de determinação significativo com nível de significância inferior a 0,05;

⁽¹⁾ Número da coleta apresentado entre parênteses;

⁽²⁾ Análise aplicada aos dados agrupados de todas as coletas.

4.5.2. Determinação do TFN por meio de Índices de Vegetação citados na literatura

Todos os IVs avaliados por este trabalho utilizam bandas específicas do espectro eletromagnético e já foram citados na literatura com potencial para avaliar a resposta da cana-de-açúcar à adubação nitrogenada aplicada. Na Tabela 2, apresentada no tópico 3.3.3.2, estão detalhadas as fórmulas matemáticas e comprimentos de onda utilizados por cada IV.

Na Tabela 9, foram apresentados os resultados das regressões lineares simples com cada um dos IVs para a predição do TFN, de acordo com os diferentes DAC da cultura. Analisando os resultados apreendidos nessa tabela, verifica-se que, mais uma vez, os modelos calibrados com os espectros coletados aos 144 DAC (coleta 3) obtiveram melhores predições do TFN, sendo esta a única coleta a apresentar R^2 significativo na validação dos modelos.

Tabela 9. Figuras de mérito da calibração e validação dos 4 Índices de Vegetação selecionados para predição do TFN, de acordo com os DAC da cultura

DAC e Coleta ⁽¹⁾	Índice	Calibração				Validação			
		R ²	RMSE (g kg ⁻¹)	RE (%)	RPD	R ²	RMSE (g kg ⁻¹)	RE (%)	RPD
Geral ⁽²⁾	ISR	0,01	2,47	18,24	1,01	0,02	2,47	18,15	1,02
	NDRE	0,00	2,49	18,34	1,00	0,01	2,50	18,34	1,01
	NDI	0,00	2,49	18,34	1,00	0,01	2,49	18,30	1,01
	RSI	0,00	2,48	18,31	1,01	0,02	2,48	18,24	1,01
67 (1)	ISR	0,03	2,37	13,67	1,03	0,04	2,59	14,34	0,94
	NDRE	0,04	2,35	13,56	1,04	0,00	2,66	14,52	0,94
	NDI	0,04	2,36	13,59	1,04	0,01	2,68	14,60	0,94
	RSI	0,04	2,36	13,58	1,04	0,01	2,68	14,63	0,94
99 (2)	ISR	0,30	1,42	14,28	1,24	0,14	1,75	15,92	0,82
	NDRE	0,38	1,33	13,45	1,31	0,10	1,75	15,92	0,82
	NDI	0,35	1,37	13,78	1,28	0,17	1,81	16,46	0,80
	RSI	0,32	1,40	14,07	1,25	0,20	1,92	17,48	0,75
144 (3)	ISR	0,42	1,24	9,17	1,36	0,60	1,27	9,97	1,50
	NDRE	0,52	1,12	8,31	1,49	0,67	1,13	8,84	1,69
	NDI	0,43	1,22	9,03	1,37	0,56	1,43	11,23	1,33
	RSI	0,31	1,35	9,98	1,24	0,49	1,50	11,76	1,27
164 (4)	ISR	0,24	1,07	7,27	1,19	0,20	1,50	10,05	1,16
	NDRE	0,26	1,06	7,18	1,20	0,20	1,50	10,05	1,16
	NDI	0,25	1,07	7,23	1,19	0,25	1,46	9,76	1,20
	RSI	0,22	1,08	7,34	1,17	0,26	1,45	9,72	1,20
200 (5)	ISR	0,13	1,59	11,34	1,11	0,21	0,92	6,47	1,13
	NDRE	0,09	1,62	11,56	1,09	0,22	0,93	6,58	1,11
	NDI	0,22	1,50	10,74	1,17	0,27	0,89	6,30	1,16
	RSI	0,28	1,44	10,32	1,22	0,26	0,86	6,08	1,20
228 (6)	ISR	0,01	1,30	10,19	1,04	0,15	1,46	11,73	0,95
	NDRE	0,00	1,31	10,24	1,04	0,15	1,40	11,23	0,99
	NDI	0,00	1,31	10,25	1,04	0,29	1,35	10,77	1,03
	RSI	0,02	1,30	10,17	1,04	0,00	1,30	10,38	1,01
255 (7)	ISR	0,00	1,44	11,26	1,04	0,15	1,81	14,27	1,04
	NDRE	0,00	1,44	11,25	1,04	0,12	1,80	14,20	1,04
	NDI	0,00	1,44	11,26	1,04	0,16	1,81	14,27	1,04
	RSI	0,00	1,44	11,25	1,04	0,17	1,82	14,34	1,03

Valores de R² em negrito indicam coeficiente de determinação significativo com nível de significância inferior a 0,05;

⁽¹⁾ Número da coleta apresentado entre parênteses;

⁽²⁾ Análise aplicada aos dados agrupados de todas as coletas.

Direcionando a análise da Tabela 9 apenas para a coleta 3, verifica-se que o índice NDRE se destacou frente aos demais por apresentar, na validação, valores de R² e RPD mais altos e RMSE e RE inferiores, quando comparados aos demais índices. Destaca-se que, embora a regressão com este índice tenha apresentado valor de R² entre a faixa de 0,66 e 0,86, sendo considerado um bom modelo de predição (SAEYS et al., 2005), o seu RPD apresentou-se inferior a 2,00, o que caracteriza

um modelo de predição razoável (CHANG et al., 2001). Esta observação ressalta a importância de se utilizar mais de uma figura de mérito para avaliação de modelagens quantitativas, uma vez que alguns indicadores de qualidade podem ser mascarados.

O NDRE, citado por Martins (2016) e também por outros autores (AMARAL et al., 2015a; AMARAL et al., 2015b), é um Índice de Vegetação por diferença normalizada que emprega as regiões do *red-edge* (em 730 nm) e do infravermelho próximo (em 780 nm). Este índice é conhecido por ser menos influenciado pela cor do dossel de plantas e do solo, sendo assim mais eficiente para a predição da biomassa da cana-de-açúcar, se comparado com IVs que utilizam a região do visível (AMARAL et al., 2015a). No trabalho de Martins (2016), este índice obteve bons resultados para a predição do TFN na variedade de cana IAC 95-500 (mesma variedade do presente trabalho), com R^2 de 0,72 na validação. Ressalta-se que estes resultados foram encontrados pelo autor para reflectância coletada em folhas de cana (não em dossel) e em condições de laboratório, quando a cultura se encontrava com aproximadamente com 90 DAC. Dessa forma, apesar dos resultados encontrados por Martins (2016) terem sido melhores, provavelmente devido às condições controladas da aquisição espectral, os valores de R^2 encontrados por ambos os trabalhos se encontram na mesma classificação, segundo Saeys et al. (2005).

Ainda analisando a coleta 3 (Tabela 9), verifica-se, conforme as figuras de mérito apresentadas, que o segundo índice de maior destaque foi o ISR, seguido pelos índices NDI e RSI. O ISR é um Índice de Vegetação por razão simples, que utiliza bandas localizadas na região da laranja³ e infravermelho próximo (em 590 nm e 880 nm, respectivamente). No trabalho de Amaral e Molin (2014), apesar de este índice não ter apresentado modelos satisfatórios para a predição de TFN, os autores o citam como promissor para monitoramento da resposta em produtividade da cana-de-açúcar. Os resultados obtidos com este IV apontaram-no como razoável para a predição do TFN aos 144 DAC (R^2 de 0,60 e RPD de 1,50, na validação).

Os índices de vegetação por diferença normalizada (NDI) e por razão espectral (RSI), ambos propostos por Miahokasap et al. (2012), trabalham com regiões específicas do *red-edge* (700, 724 e 750 nm). Ambos foram obtidos pelos autores valendo-se de técnicas de mineração de dados (data mining) sobre dados espectrais obtidos com o sensor hiperespectral FieldSpec 3 (Analytical Spectral Devices – ASD, Boulder, CO, USA). Neste trabalho, os autores relataram que tais IVs destacaram-se dentro de 1.025 outros índices gerados com combinações de 2 bandas espectrais, apresentando R^2 na validação superior a 0,7 para a predição do TFN. No atual trabalho, ambos os IVs apresentaram figuras de mérito qualificando-os como não confiáveis para a predição do TFN (Tabela 9). Os resultados menos promissores observados para ambos os índices provavelmente estão relacionados à época em que os autores os quais os propuseram coletaram os espectros em campo. Miahokasap et al. (2012) relataram haverem coletado os espectros da cultura da cana quando esta estava com 9 meses em campo (c. 270 DAC).

³ Este comprimento de onda está situado entre as mudanças da região do amarelo para a região do laranja no espectro eletromagnético, sendo assim, um comprimento de onda muito próximo da região do verde. Desta forma, é comum este comprimento de onda ser mencionado por alguns trabalhos como pertencente à região do verde.

Além dos 4 IVs, também selecionou-se na literatura uma regressão linear múltipla proposta por Barros (2016), a qual apresentou bons resultados para a predição do TFN. Esta regressão múltipla envolve apenas 2 comprimentos de onda da região do *red-edge* (710 e 720 nm), os quais foram selecionados pelo autor por meio dos métodos de seleção de variáveis de sPLS + *Stepwise*. Em seu trabalho, Barros (2016) gerou este modelo de predição do TFN com os espectros obtidos sobre o dossel de cana, quando ela se encontrava com 146 DAC, ou seja, condições próximas às desenvolvidas por este trabalho. Por outro lado, é válido ressaltar também que em seu trabalho, o referido autor gerou um modelo generalista com dados obtidos sobre as variedades de cana SP 81-3250, a RB 92579 e a RB 86-7515, sendo todas variedades distintas das utilizadas no presente trabalho.

Na Tabela 10, foram apresentados os resultados das figuras de mérito para a validação da regressão proposta por Barros (2016), assim como as figuras de mérito de uma nova calibração e validação realizadas para os dados do presente trabalho, empregando as mesmas bandas utilizadas pelo autor.

Ao se analisar a validação do modelo de regressão proposto nos dados coletados pelo presente trabalho, verifica-se que este não se validou em nenhuma das coletas, uma vez que os seus valores de R^2 foram sempre inferiores a 0,12 e a RPD sempre inferior a 0,28. No entanto, ao se utilizar os mesmos comprimentos de onda em uma nova calibração e validação, as novas figuras de mérito da validação melhoram para todas as coletas (Tabela 10). Inclusive, aos 144 DAC (coleta 3) – momento próximo ao utilizado por Barros (2016) para a calibração do modelo –, as figuras de mérito se mostraram próximas às obtidas pelo autor, o qual encontrou R^2 de 0,55 e RMSE de 1,38 e as obtidas pelo presente trabalho foram 0,44 e 1,44 para o R^2 e o RMSE, respectivamente.

Ben Dor et al. (2015) afirmam que, para gerar modelos de predição replicáveis utilizando dados de reflectância espectral, é importante não só a escolha correta dos comprimentos de onda, mas também o controle dos efeitos que possam influenciar a intensidade e o formato da curva espectral (albedo). O autor ainda comenta que o sucesso da replicação de modelos utilizando reflectância espectral e, inclusive o compartilhamento de bibliotecas espectrais, só será possível se houver a criação de protocolos de padronização para as análises espectrais que visem minimizar efeitos de fatores aleatórios e sistemáticos que influenciam no albedo das curvas coletadas.

Assim, pode-se inferir que a limitação do modelo de regressão proposto por Barros (2016) não se encontra nos comprimentos de onda utilizados, mas sim devido à falta de um sólido protocolo de padronização da aquisição de dados espectrais no campo, utilizando sensores passivos em experimentos agrônômicos, o que faz ocorrerem alterações no albedo das curvas espectrais. Por outro lado, reitera-se que, como esta padronização da variabilidade espacial e temporal da iluminação do ambiente se mostra difícil em condições de campo (SOUZA et al., 2010; HOLLAND et al., 2012), sensores hiperespectrais devem ser utilizados para fins de pesquisa, com o intuito de identificar bandas específicas que melhor se relacionem com o atributo de interesse. Processo este que, por sua vez, deve estimular o desenvolvimento de sensores ativos empregando estas bandas predeterminadas, os quais serão específicos para certa cultura e parâmetro a ser predito.

Tabela 10. Figuras de mérito da validação da regressão proposta por Barros (2016) e da calibração e validação da regressão múltipla, utilizando as mesmas bandas da regressão de Barros (2016), ambos para a predição do TFN de acordo com os DAC da cultura

DAC e Coleta ⁽¹⁾	Regressão	Calibração				Validação			
		R ²	RMSE (g kg ⁻¹)	RE (%)	RPD	R ²	RMSE (g kg ⁻¹)	RE (%)	RPD
Geral ⁽²⁾	Reg. Barros (2016)	-	-	-	-	0,07	8,89	65,39	0,28
	Reg. múltipla com bandas de Barros (2016)	0,04	2,44	17,95	1,03	0,12	2,36	17,32	1,06
67 (1)	Reg. Barros (2016)	-	-	-	-	0,00	8,87	51,06	0,28
	Reg. múltipla com bandas de Barros (2016)	0,08	2,32	13,09	1,08	0,00	2,79	15,29	0,94
99 (2)	Reg. Barros (2016)	-	-	-	-	0,00	9,62	92,31	0,17
	Reg. múltipla com bandas de Barros (2016)	0,24	1,47	14,85	1,19	0,14	1,72	15,68	0,84
144 (3)	Reg. Barros (2016)	-	-	-	-	0,01	6,92	52,67	0,26
	Reg. múltipla com bandas de Barros (2016)	0,45	1,20	8,93	1,39	0,44	1,44	11,29	1,32
164 (4)	Reg. Barros (2016)	-	-	-	-	0,12	7,80	52,58	0,19
	Reg. múltipla com bandas de Barros (2016)	0,28	1,04	7,05	1,22	0,25	1,46	9,76	1,20
200 (5)	Reg. Barros (2016)	-	-	-	-	0,03	5,40	38,38	0,27
	Reg. múltipla com bandas de Barros (2016)	0,32	1,40	9,99	1,26	0,13	0,96	6,76	1,08
228 (6)	Reg. Barros (2016)	-	-	-	-	0,00	10,25	81,05	0,13
	Reg. múltipla com bandas de Barros (2016)	0,18	1,19	9,28	1,14	0,11	1,71	13,72	0,81
255 (7)	Reg. Barros (2016)	-	-	-	-	0,00	9,84	77,24	0,17
	Reg. múltipla com bandas de Barros (2016)	0,00	1,44	11,24	1,04	0,06	1,82	14,35	1,03

Valores de R² em negrito indicam coeficiente de determinação significativo com nível de significância inferior a 0,05;

⁽¹⁾ Número da coleta apresentado entre parênteses;

⁽²⁾ Análise aplicada aos dados agrupados de todas as coletas.

4.5.3. Determinação do TFN por seleção de variáveis e regressão linear múltipla

Os métodos de seleção de variáveis utilizados para a escolha de comprimentos de onda que alimentaram as regressões múltiplas propostas por este tópico foram o sPLS e o *Stepwise*. No entanto, a fim de comparação, também foram calculados os coeficientes de correlação entre cada comprimento de onda e o TFN.

O resultado mostrando os melhores comprimentos de onda indicados por cada um dos métodos está apresentado na Tabela 11. Na análise envolvendo o coeficiente de correlação, foram apresentados os 10 coeficientes de correlação mais altos (analisados em módulo); já para a análise com o sPLS + *Stepwise*, foram selecionados os 10 coeficientes mais altos indicados pelo sPLS, os quais foram submetidos à análise pelo método de *Stepwise*. Todos comprimentos de onda indicados por este último método foram apresentados na Tabela 11. Os valores dos coeficientes de correlação dos comprimentos de onda que se destacaram estão apresentados no Apêndice 6.

Tabela 11. Comprimentos de onda selecionados pelos métodos do coeficiente de correlação e por sPLS + *Stepwise* que melhor se correlacionam com o TFN, de acordo com os DAC da cultura

DAC e coleta ⁽¹⁾	Coeficiente de correlação		sPLS + <i>Stepwise</i>	
	Comp. de onda (nm)	Regiões espectrais	Comp. de onda (nm)	Regiões espectrais
Geral ⁽²⁾	718, 719, 720, 721, 722, 723, 724, 893, 897 e 898	<i>Red-edge</i> e infravermelho próximo	449, 473, 474, 505, 506, 515 e 519	Azul e verde
67 (1)	400, 401, 419, 420, 433, 863, 895, 896, 899 e 900	Azul e infravermelho próximo	419, 511 e 512	Azul e verde
99 (2)	779, 780, 781, 785, 789, 790, 794, 795, 802 e 816	Infravermelho próximo	402, 403, 404, 405, 424, 426, 430 e 434	Azul
144 (3)	786, 795, 796, 797, 802, 805, 806, 807, 812 e 813	Infravermelho próximo	490, 647, 652, 692, 707 e 721	Verde, vermelho e <i>red-edge</i>
164 (4)	400, 401, 670, 671, 674, 675, 676, 679, 680 e 690	Azul e vermelho	400, 537, 543, 548, 549, 550, 579, 584 e 710	Azul, verde, amarelo e <i>red-edge</i>
200 (5)	671, 672, 674, 675, 676, 677, 678, 680, 683, 684	Vermelho	662, 663, 664, 665, 666, 668, 681, 683 e 684	Vermelho e <i>red-edge</i>
228 (6)	759, 760, 761, 776, 777, 778, 779, 782 e 788	Infravermelho próximo	759, 768, 769, 770, 771, 775, 776 e 788	Infravermelho próximo
255 (7)	402, 403, 404, 405, 416, 417, 418, 420 e 428	Azul	401, 406, 407, 599, 600, 601, 602, 603, 605 e 606	Azul e laranja

Comprimentos de onda em negrito, na análise por coeficiente de correlação, indicam que eles obtiveram correlação significativa com nível de significância de 0,05;

⁽¹⁾ Número da coleta apresentado entre parênteses;

⁽²⁾ Análise aplicada aos dados agrupados de todas as coletas.

Voltando à análise da Tabela 11 para a coleta 3 (144 DAC) – momento verificado pelas análises anteriores como mais promissor à estimativa do TFN – observa-se que os comprimentos de

onda e as regiões espectrais escolhidos pelos 2 métodos não se concordaram. O coeficiente de correlação apontou comprimentos de onda do infravermelho próximo, enquanto que o método conjunto utilizando sPLS + *Stepwise* indicou comprimentos de onda do azul, vermelho e do *red-edge*.

Os comprimentos de onda selecionados pelo método do coeficiente de correlação foram praticamente consecutivos e todos pertencentes a apenas uma região espectral, indicando fortemente serem correlatos entre si. Esta é uma característica deste método, que não leva em consideração a colinearidade entre os dados analisados: comprimentos de onda da região do infravermelho próximo apresentam reflectância com valores próximos entre si e consequentemente são colineares. Thenkabail et al. (2000), ao avaliarem diferentes culturas agrícolas, relataram que o comportamento de reflectância da região do infravermelho próximo, mais especificamente entre 740 e 875 nm, foi praticamente constante e todos os comprimentos de onda apresentaram alta correlação com o IAF das culturas analisadas.

O método conjunto do sPLS + *Stepwise* foi escolhido para a seleção de variáveis, pois, segundo Glantz e Slinker (1990), ele permite estabelecer modelos de regressão mais confiáveis, porque o processo de inserção de variáveis dependentes é gradual e sequencial, de forma que uma variável é inserida de cada vez em uma equação de regressão. Demattê et al. (2015) complementam que este método é particularmente útil em situações que envolvem grande conjunto de dados, com muitas variáveis independentes.

De fato, pode-se perceber que na coleta 3 (Tabela 11) o método envolvendo o sPLS + *Stepwise* selecionou comprimentos de onda de distintas regiões do espectro eletromagnético, sendo mais eficiente em contornar a colinearidade existente em comprimentos de onda próximos entre si. Assim, segundo este método, as variáveis espectrais que mais se destacaram foram 490 nm da região do verde; 647, 652 e 692 nm da região do vermelho e 707 e 721 nm da região do *red-edge*.

Jensen (2009) afirma que toda a região do visível é influenciada pelos pigmentos presentes nas folhas, sendo que as principais feições de absorção da clorofila estão entre 430 e 450 nm (região do azul) e entre 650 e 660 nm (região do vermelho). Contudo, a análise de remoção do contínuo, apresentada na Figura 8, mostrou que nos dados do presente trabalho as feições de absorção de clorofila da cana-de-açúcar se encontram um pouco mais à frente da região mencionada pelo autor, apresentando picos de absorção em 495 e 680 nm. Assim, dos comprimentos de onda selecionados dentro da região do visível, 490 e 692 nm situaram-se dentro das feições da clorofila, bem próximos dos picos de absorção observados para a cultura da cana-de-açúcar. Ressalta-se também que embora os comprimentos de onda 647 e 652 nm estejam mais afastados do pico de absorção de clorofila, ambos encontram-se em uma região espectral onde foi possível observar a sua resposta às doses de N aplicadas (Figura 9).

Utilizando os comprimentos de onda indicados pelo método sPLS + *Stepwise* com boa relação com o TFN em cada coleta, foram propostas regressões lineares múltiplas. Os resultados das figuras de mérito dessas regressões estão apresentados na Tabela 12.

Tabela 12. Calibração e validação de modelos de Regressão Linear Múltipla com seleção de variáveis por sPLS + Stepwise para a predição do TFN, de acordo com os DAC da cultura

DAC e coleta ⁽¹⁾	Equação ⁽³⁾	Calibração				Validação			
		R ²	RMSE (g kg ⁻¹)	RE (%)	RPD	R ²	RMSE (g kg ⁻¹)	RE (%)	RPD
Geral ⁽²⁾	$Y = 16,55 + 673,98 * B449 - 1429,72 * B473 + 1475 * B474 + 2328,40 * B505 - 1992,83 * B506 - 1920,03 * B515 + 1008,41 * B519$	0,30	2,08	15,34	1,20	0,34	2,03	14,88	1,28
67 (1)	$Y = 5,58 + 1188,41 * B419 - 285,51 * B511 - 152,78 * B512$	0,37	1,91	10,79	1,31	0,08	2,37	13,97	1,03
99 (2)	$Y = 13,36 - 3354,22 * B402 + 3400,53 * B403 - 1082,47 * B405 + 3718,34 * B424 + 1456,86 * B426 - 1977,01 * B430 - 2331,72 * B434$	0,84	0,67	6,78	2,6	0,25	2,02	18,37	0,71
144 (3)	$Y = 22,27 + 996,04 * B490 - 2710,18 * B647 + 1544,23 * B652 + 763,99 * B692 - 138,72 * B707 - 59,86 * B721$	0,75	0,81	6,01	2,06	0,33	1,60	12,56	1,19
164 (4)	$Y = 21,04 + 575,89 * B400 + 1896,05 * B537 - 3272,49 * B543 + 1261,19 * B548 - 70,5818 * B549 + 471,83 * B550 - 3449,51 * B579 + 4635,70 * B584 - 805,89 * B710$	0,80	0,55	3,71	2,32	0,13	1,78	11,90	0,98
200 (5)	$Y = 20,66 - 15,394,06 * B662 + 176941,17 * B663 - 455494,94 * B664 + 498777,43 * B665 - 233691,32 * B666 + 29574,34 * B668 + 2446,51 * B681 - 8979,82 * B683 + 5620,63 * B684$	0,77	0,81	5,79	2,17	0,14	1,29	9,12	0,80
228 (6)	$Y = 18,09 + 92,51 * B759 + 3672,56 * B768 - 8043,45 * B769 + 7329,16 * B770 - 4629,97 * B771 + 9368,62 * B775 - 9427,95 * B776 + 1613,80 * B788$	0,66	0,77	6,02	1,76	0,21	1,99	15,95	0,70
255 (7)	$Y = 12,87 - 205,21 * B401 + 67,50 * B406 + 563,73 * B407 + 94026,63 * B599 - 730870,16 * B600 + 1759314,123 * B601 - 1855437,76 * B602 + 807375,85 * B603 - 98861,10 * B605 + 24398 * B606$	0,48	1,03	8,10	1,44	0,05	1,88	14,79	1,00

Valores de R² em negrito indicam coeficiente de determinação significativo com nível de significância inferior a 0,05;

⁽¹⁾ Número da coleta apresentado entre parênteses;

⁽²⁾ Análise aplicada aos dados agrupados de todas as coletas;

⁽³⁾ Nas equações, valor numérico precedido da letra B representa o comprimento de onda utilizado no modelo.

Ao se analisar, na Tabela 12, os resultados das figuras de méritos na validações nas diferentes coletas, verifica-se que em nenhum momento as regressões geradas por este método apresentaram resultados expressivos. Nenhum valor de R² se mostrou superior a 0,5, limite inferior para ser considerado um modelo razoável (SAEYS et al., 2005), e todos valores de RPD foram inferiores a 1,40, indicando serem modelos não confiáveis (CHANG et al., 2001). Tampouco aos 144 DAC, momento que apresentou bons resultados em análises anteriores, a regressão múltipla se mostrou promissora.

4.5.4. Determinação do TFN por seleção de variáveis e novos Índices de Vegetação

Nesta etapa, foram testados novos IVs, os quais foram gerados utilizando as fórmulas do IRS e IDN e realizando diferentes combinações dos valores de reflectância dos comprimentos de onda selecionados pelo método conjunto do sPLS + *Stepwise* (conforme detalhado no tópico 3.3.3.4). Os 10 IVs que apresentaram modelo de regressão com melhor desempenho foram apresentados na Tabela 13.

Ao comparar os resultados das regressões apresentados na Tabela 13 e na Tabela 12, pode-se verificar que as figuras de mérito da Tabela 13 apresentaram melhores resultados, ou seja, predições do TFN envolvendo seleção de variáveis e IVs se mostraram superiores às predições empregando a mesma seleção de variáveis e regressão múltipla.

Tabela 13. Calibração e validação dos modelos de Regressão Linear Simples de cada IV gerado, seus respectivos comprimentos de onda utilizados e região espectral a que pertencem para a predição do TFN com a cana em 144 DAC (coleta 3) para cada índice de vegetação gerado

IVs	Comp. de onda de γ_1 e γ_2 (nm) ⁽¹⁾	Região espectral ⁽²⁾	Calibração				Validação			
			R ²	RMSE (g kg ⁻¹)	RE (%)	RPD	R ²	RMSE (g kg ⁻¹)	RE (%)	RPD
IRS	490 e 652	Verde e vermelho	0,47	1,18	8,77	1,42	0,57	1,33	10,39	1,44
IRS	490 e 647	Verde e vermelho	0,52	1,12	8,33	1,49	0,56	1,32	10,34	1,44
IDN	490 e 647	Verde e vermelho	0,53	1,11	8,27	1,50	0,56	1,35	10,60	1,41
IDN	647 e 490	Vermelho e verde	0,53	1,11	8,27	1,50	0,56	1,35	10,60	1,41
IDN	652 e 490	Vermelho e verde	0,47	1,17	8,70	1,43	0,56	1,35	10,57	1,41
IDN	490 e 652	Verde e vermelho	0,47	1,17	8,70	1,43	0,56	1,35	10,57	1,41
IRS	652 e 490	Vermelho e verde	0,48	1,16	8,62	1,44	0,55	1,40	10,97	1,36
IDN	692 e 490	Red-edge e verde	0,49	1,15	8,53	1,46	0,53	1,39	10,92	1,37
IRS	647 e 490	Vermelho e verde	0,53	1,11	8,20	1,51	0,54	1,42	11,11	1,34
IRS	692 e 490	Red-edge e verde	0,50	1,14	8,49	1,46	0,51	1,46	11,48	1,30

Valores de R² em negrito indicam coeficiente de determinação significativo com nível de significância inferior a 0,05;

⁽¹⁾ Valores dos comprimentos de onda foram utilizados na equação do IV, sendo γ_1 o primeiro comprimento de onda apresentado e γ_2 o segundo;

⁽²⁾ Regiões espectrais às quais os comprimentos de onda selecionados pertencem.

As 2 melhores regressões obtidas por este método foram as que utilizaram os índices IRS (com λ_1 em 490 nm e λ_2 em 647 nm) e IRS (com λ_1 em 490 e λ_2 em 652 nm), ambas apresentaram os melhores desempenhos de suas figuras de mérito na validação dos dados. O modelo envolvendo o IRS (com λ_1 em 490 e λ_2 em 652 nm) apresentou R² de 0,57 e RPD de 1,44 e o modelo utilizando o IRS (com λ_1 em 490 nm e λ_2 em 647 nm) obteve R² de 0,56 e RPD de 1,44.

Vale destacar que todos os modelos apresentados na Tabela 13 que obtiveram RPD superior a 1,40 – início da faixa de interpretação classificada como modelos razoáveis – utilizaram os comprimentos de onda 490 nm (região do verde), 647 e 652 nm (região do vermelho). Isso mostra que, neste método de análise quantitativa, os índices gerados com comprimentos de onda da região do visível exibiram melhores resultados que os índices que utilizaram comprimentos de onda do visível combinados a comprimentos de onda do *red-edge*.

Muito embora, ao compararmos os resultados de ambos os índices IRS (índices com apenas bandas do visível) com os resultados do índice NDRE (índice que utiliza comprimentos de onda da região do *red-edge* e do infravermelho próximo), apresentados na Tabela 9, este último se destaca por apresentar maiores valores de R^2 e RPD e menor erro. Desta forma, descarta-se para a cultura da cana-de-açúcar a hipótese de que IVs utilizando apenas regiões do visível poderiam ser melhores que a predição do TFN, a qual foi traçada levando em consideração os trabalhos de Hansen e Schjoerring (2003) e Stroppiana et al. (2009).

4.5.5. Melhores resultados a para predição TFN

Foi unânime, entre os métodos quantitativos utilizados neste trabalho, que o momento mais propício para a geração dos modelos de regressão para a predição do TFN da cana-de-açúcar analisada pelo presente trabalho é aos 144 DAC (coleta 3). Assim, na Figura 11 estão apresentados os desempenhos de RPD (na validação) dos melhores modelos de regressão para a predição do TFN aos 144 DAC, para cada um dos métodos quantitativos aplicados por este trabalho.

(¹) Resultado apresentado do índice NDRE citado por Martins (2016);

(²) Resultado apresentado do índice IRS com os comprimentos de onda 490 e 652 nm;

(³) Resultado apresentado da regressão múltipla calibrada para o conjunto de dados deste trabalho, utilizando os comprimentos de onda propostos por Barros (2016).

Figura 11. Valores de RPD (na validação) com melhores desempenhos de acordo com cada uma das avaliações quantitativas do espectro para a predição do TFN da cana aos 144 DAC (coleta 3).

Pode-se observar na Figura 11 que as regressões que mais se sobressaíram foram obtidas utilizando os IVs já propostos na literatura, com destaque aos índices NDRE e ISR, os quais

obtiveram, na validação, R^2 de 0,67 e RPD de 1,69 e R^2 de 0,60 e RPD de 1,50, respectivamente (Figura 12). Em seguida, também se destacou o método PLSR. O seu modelo de regressão apresentou R^2 de 0,63 e RPD de 1,49, na validação (Figura 12). E, finalmente, evidenciaram-se também os índices gerados após seleção de variáveis IRS (com λ_1 em 490 nm e λ_2 em 647 nm) e IRS (com λ_1 em 490 e λ_2 em 652 nm), os quais apresentaram, na validação, R^2 de 0,67 e RPD de 1,69 e R^2 de 0,60 e RPD de 1,50, respectivamente (Figura 12).

Os modelos de regressão mencionados no parágrafo anterior representam os 5 melhores resultados obtidos por este trabalho para a predição do TFN e, como já citado, todos estes modelos foram obtidos aos 144 DAC (coleta 3). Os seus modelos de regressão calibrados, assim como as suas figuras de mérito e as dispersões dos dados de calibração dos referidos modelos estão apresentadas na Figura 12.

Figura 12. Regressões e figuras de mérito da validação dos melhores modelos para a determinação do TFN (cultura aos 144 DAC) obtidas neste trabalho. (A) Regressão Linear Simples com o índice NDRE proposto por Martins (2016); (B) Regressão Linear Simples com o índice ISR proposto por Amaral e Molin (2014); (C) Regressão por Mínimos Quadrados Parciais (PLSR) com todo o espectro de 400 a 900 nm; (D) Coeficientes da PLSR; (E) Regressão Linear Simples e o índice IRS com os comprimentos de onda de 490 e 652 nm; e (F) Regressão Linear Simples e o índice IRS com os comprimentos de onda de 490 e 647 nm.

Em relação ao erro do modelo de predição (RMSE), estes 5 melhores modelos de predição mantiveram a sua ordem de destaque. O índice NDRE foi o que apresentou menor erro de predição (RMSE de $1,13 \text{ g kg}^{-1}$), seguido pelo índice ISR e o modelo da PLSR (RMSE de $1,27$ e $1,28 \text{ g kg}^{-1}$, respectivamente). E, por fim, pelos índices gerados após seleção de variáveis IRS (com λ_1 em 490 nm e λ_2 em 647 nm) e IRS (com λ_1 em 490 e λ_2 em 652 nm), os quais apresentaram RMSE de $1,32$ e $1,33 \text{ g kg}^{-1}$, respectivamente.

Para a comparação e interpretação dos resultados da análise foliar para a cultura da cana-de-açúcar, Raij et al. (1997) propuseram a faixa de 18 a 25 g kg⁻¹ como quantidade adequada deste nutriente na folha, sendo assim, um erro de 1,13 a 1,28 g kg⁻¹ pode ser considerado baixo. Porém, os valores de R² e RPD alertam pelo fato de que em todos estes 5 modelos, os seus valores oscilaram entre a faixa interpretada como modelos de predição razoáveis, que apenas podem diferenciar altas e baixas doses do atributo em questão.

Acredita-se que a predição razoável dos modelos de predição encontrados por este trabalho, em paralelo às predições boas encontradas por outros trabalhos da literatura (PORTZ et al., 2012a; PORTZ et al., 2012b) esteja relacionada a fatores como: (i) a resposta variável da cultura de açúcar à adubação nitrogenada, que pode incrementar ou diminuir a variabilidade do TFN em função do experimento avaliado, facilitando ou dificultando a modelagem deste parâmetro; (ii) o fato de que a resposta espectral de dossel de plantas é governada por fatores que não especificamente o TFN, sendo, portanto, a predição deste uma determinação indireta; (iii) a dificuldade de controle de fatores sistemáticos em espectroscopia de campo.

Ressalta-se também que os resultados apresentados por este trabalho indicam o NDRE, o qual utiliza os comprimentos de onda 720 e 780 nm (pertencentes à região do *red-edge* e do infravermelho próximo), como o índice mais propício à predição do TFN aos 144 DAC. Os índices IRSs (Figura 11E e F), envolvendo apenas comprimentos de onda da região do visível, também apresentaram desempenho de figuras de mérito classificados na mesma faixa de interpretação do índice NDRE.

5. CONCLUSÕES

Os resultados obtidos pelo presente trabalho mostraram ser possível uma razoável predição do TFN da cana-de-açúcar por meio de espectroscopia *in situ*. Por sua vez, neste trabalho, esta janela de predição se revelou curta, situando-se em torno dos 144 DAC. Mais pesquisas são necessárias para o correto entendimento dos fatores que influenciam a resposta espectral da cana ao TFN;

Os IVs avaliados que mais se destacaram para a predição do TFN utilizaram os comprimentos de onda: 490 nm da região do verde; 590 nm da região do laranja; 647 e 652 nm da região do vermelho; 730 nm da região do *red-edge*; e 780 e 880 nm da região do infravermelho próximo. O IV que mais se destacou foi o NDRE, índice já sugerido pela literatura com bons resultados para a determinação da biomassa da cana-de-açúcar.

Os métodos de predição envolvendo os IVs propostos na literatura, PLSR e IVs criados a partir de comprimentos de onda selecionados pela seleção de variáveis sPLS + *Stepwise* demonstraram os melhores resultados para a predição do TFN. Estes métodos exibiram modelos de predição, em sua maioria, classificados como razoáveis para a predição do TFN, podendo distinguir altas e baixas concentrações desta variável.

6. CONSIDERAÇÕES FINAIS

Trabalhos envolvendo sensores passivos *in situ* necessariamente seguem algumas precauções para coleta do espectro no campo para evitar a interferência de efeitos sistemáticos no espectro coletado. Estas precauções dizem respeito: ao intervalo de horário em que a técnica deve ser aplicada para se evitar variações no espectro causadas pela posição solar; a cuidados com as calibrações do aparelho, para se evitar que a radiação incidente se altere após que sensor já esteja calibrado, entre algumas outras. No entanto, durante a realização deste trabalho, notou-se que as variações espectrais em função das oscilações do TFN se expressam de maneira sutil, levando a acreditar que para avaliação mais clara destas variações e, com isto a avaliação do real potencial da técnica, as interferências dos efeitos sistemáticos sobre os espectros devem ser levadas em consideração.

Estudos mais aprofundados nos efeitos sistemáticos que possam estar interferindo na resposta espectral dos dosséis de plantas poderiam ser conduzidos de modo a facilitar o ajuste de um protocolo sólido para a padronização das coletas espectrais *in situ*, semelhante ao que já é praticado na espectrorradiometria de laboratório para análises de solos. Assim, para futuros trabalhos utilizando sensores ópticos passivos hiperespectrais na avaliação do TFN, recomenda-se que sejam avaliados os fatores sistemáticos que possivelmente possam estar mascarando a avaliação do espectro em relação à variação do TFN. Citam-se como fatores sistemáticos importantes a serem observados: características intrínsecas do sensor, fenologia da cultura, condições de estresse da planta dadas as variáveis climáticas, variação da altura entre sensor e planta em função dos diferentes níveis de crescimento dentro do talhão, geometria entre sol, planta e sensor.

REFERÊNCIAS

- AMARAL, L. R. **Sensor de refletância do dossel para direcionar a aplicação de nitrogênio em taxas variadas na cultura da cana-de-açúcar**. 2014. 132 p. Tese (Doutorado) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2014.
- AMARAL, L.R.; MOLIN, J.P. Sensor óptico no auxílio à recomendação de adubação nitrogenada em cana-de-açúcar. **Pesquisa Agropecuária Brasileira**, v. 16, n. 1, p. 1633–1642, 2011.
- AMARAL, L. R.; MOLIN, J. P. The effectiveness of three vegetation indices obtained from a canopy sensor in identifying sugarcane response to nitrogen. **Agronomy Journal**, v. 106 , p. 273-280, 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**, v. 107, n. 4, p. 1513-1523, 2015a.
- 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**, v. 16, n. 1, p. 15-28, 2015b.
- ANDRADE, R. G.; VICENTE, L. E., TEIXEIRA, A. H. de C., LEIVAS, J. F., VICTORIA, D. de C., ROGGIA, S., FRANCHINI, J. C., Uso do sensoriamento remoto na obtenção de parâmetros biofísicos em plantios de soja. **Agricultura de precisão: resultados de um novo olhar**. Brasília: Embrapa, 2014.
- BARROS, P. P. da S. **Dados hiperespectrais de dossel e sua correlação com nitrogênio aplicado a cultura da cana-de-açúcar**. 2016. 132 p. Tese (Doutorado) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2016.
- BEN DOR, E.; ONG, C.; LAU, I.C. Reflectance measurements of soils in the laboratory: Standards and protocols. **Geoderma**, v. 245-246, p. 112-124, 2015.
- BOUWMAN, A. F.; BOUMANS, L. J. M.; BATJES, N. H. Emissions of N₂O and NO from fertilized fields: Summary of available measurement data. **Global Biogeochemical Cycles**, v. 16, n. 4, 2002.
- BOX, G.E.P.; COX, D.R. An analysis of transformation. **Journal of the Royal Statistical Society**, v. 26, p. 211-252, 1964.
- BREDEMEIER, C.; SCHMIDHALTER, U. Laser-induced chlorophyll fluorescence sensing to determine biomass and nitrogen uptake of winter wheat under controlled environment and field conditions. **Precision Agriculture**, p. 273-280, 2005.
- BREUNIG, F. M.; CAMARGO, F. F.; ADAMI, M.; MANTELLI, L. R.; COSTA, M. C. da; PONZONI, F. J.; FREITAS, J. G. de. Aplicação da técnica de remoção do contínuo para a discriminação espectral de diferentes dosagens de Nitrogênio aplicadas ao trigo (*Triticum aestivum*, L.-IAC-370). **Simpósio Brasileiro de Sensoriamento Remoto**, v. 13, p. 91-98, 2007.
- BROWN, S.D. Chemical systems under indirect observation: latent properties and chemometrics. **Applied Spectroscopy**, v.12, p.14-31, 1995.
- BROWN, D.J.; SHEPHERD, K.D.; WALSH, M.G.; Dewayne Mays, M.; Reinsch, T.G. Global soil characterization with VNIR diffuse reflectance spectroscopy. **Geoderma**, v. 132, p. 273–290, 2006.
- CANTARELLA, H. Nitrogênio. In: NOVAIS, R.F.; ALVAREZ, V. H.; BARROS, N. F.; FONTES, R. L. F.; CANTARUTTI, R. B.; NEVES, J. C. L. (Ed.). **Fertilidade do solo**. Viçosa: SBCS, 2007. p. 375-470.
- CAO, Q.; MIAO, Y.; WANG, H.; HUANG, S.; CHENG, S.; KHOSLA, R.; JIANG, R. Non-destructive estimation of rice plant nitrogen status with Crop Circle multispectral active canopy sensor. **Field**

Crops Research, v. 154, p. 133–144, 2013.

CAO, Q.; MIAO, Y.; LI, F.; LU, D. Precision nitrogen management strategy for winter wheat in the North China Plain based on an active canopy sensor. In: **Precision agriculture'15**. Wageningen Academic Publishers, 2015. p. 1687-1693.

CHANG, C. W.; LAIRD, D. A.; MAUSBACH, M. J.; HUBURGH, C. R. Near-infrared reflectance spectroscopy-principal components regression analyses of soil properties. **Soil Science Society of American Journal**, v. 65, p. 480 - 900, 2001.

CHUN, H.; KELES, S. Sparse partial least squares regression for simultaneous dimension reduction and variable selection. **Journal of the Royal Statistical Society**, v. 72, p. 3 – 25, 2010.

CHUNG, D.; CHUN, H. An introduction to the “spl” Package, Version 1.0. 2012.

CLARK, R.N.; ROUSH, T.L. Reflectance spectroscopy: quantitative analysis techniques for remote sensing applications. **Journal of Geophysical Research**. v. 89, n. B7, p. 6329-6340, 1984.

CONAB – Companhia Nacional de Abastecimento. Acompanhamento da safra brasileira de cana-de-açúcar, v. 2 – Safra 2015/16, n.3 – terceiro levantamento, Brasília, p.1-65, dezembro 2015.

CROSTA, A.P. Análise por componentes principais. In: _____. Processamento digital de imagens de sensoriamento remoto. Campinas: UNICAMP, 1992. cap. 9, p. 123-137.

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**, v. 63, n. 4, p. 409–426, 2008.

DHAWALE, N. M.; ADAMCHUK, V. I.; PRASHER, S. O.; VISCARRA ROSSEL, R. a.; ISMAIL, A. A.; KAUR, J. Proximal soil sensing of soil texture and organic matter with a prototype portable mid-infrared spectrometer. **European Journal of Soil Science**, v. 66, n. July 2016, p. 661–669, 2015.

DEBAENE, G.; NIEDŹWIECKI, J.; PECIO, A.; ZUREK, A. Effect of the number of calibration samples on the prediction of several soil properties at the farm-scale. **Geoderma**, v. 214-215, p. 114–125, 2014.

DEMATTÊ, J. A. M.; ALVES, M. R.; GALLO, B. C.; FONGARO, C. T.; SOUZA, A. B.; ROMERO, D. J.; SATO, M. V. Hyperspectral remote sensing as an alternative to estimate soil attributes. **Revista Ciencia Agronomica**, v. 46, n. 2, p. 223–232, 2015.

DEMATTÊ, J. A.; OLIVEIRA, J. de C.; TAVARES, T. R.; LOPEZ, L. R.; TERRA, F. da S., ARAÚJO, S. R., FONGARO, C. T.; MAIA, S. M. F.; MELLO, F. F. de C.; RIZZO, R.; VICENTE, S.; BORBOLLETO, M. A. DE M.; CERQUEIRA, P. H. R. Soil chemical alteration due to slaughterhouse waste application as identified by spectral reflectance in São Paulo State, Brazil: an environmental monitoring useful tool. **Environmental Earth Sciences**, v. 75, n. 18, p. 1277, 2016.

EICKHOUT, B.; BOUWMAN, A. F. van; VAN ZEIJTS, H. The role of nitrogen in world food production and environmental sustainability. **Agriculture, ecosystems & environment**, v. 116, n. 1, p. 4-14, 2006.

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**, v. 112, p. 2033–2050, 2008.

FRANCO, C. F. Amostragem de folha em cana-de-açúcar submetida à adubação nitrogenada. **Revista de Agricultura**, v. 83, n. 1, p. 8-18, 2008.

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**, v. 67, p. 579–590, 2010.

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

GAVA, G. J. C.; TRIVELIN, P. C. O.; OLIVEIRA, M. W.; PENATTI, C. P. Crescimento e acúmulo de nitrogênio em cana-de-açúcar cultivada em solo coberto com palhada. **Pesquisa Agropecuária Brasileira**, v. 36, p. 1347-1354, 2001.

GALUSZKA, A.; MIGASZEWSKI, Z. M.; NAMIESNIK, J. Moving your laboratories to the field - Advantages and limitations of the use of field portable instruments in environmental sample analysis. **Environmental Research**, v. 140, p. 593-603, 2015.

GALVÃO, L.S.; PIZARRO, M.A.; EPIPHANIO, J.C.N. Variations in reflectance of tropical soils: spectral-chemical compositions relationships from AVIRIS data. **Remote Sensing of Environment**, v. 75, p. 245-255, 2001.

GLANTZ, S. A.; SLINKER, B. K. **Primer of applied regression and analysis of variance**. New York: MacGraw- Hill, 1990. p. 320.

GOLTZ, E. **Avaliação do produto MOD09 (reflectância da superfície) fornecido pelo sensor MODIS/Terra através de radiometria de campo em uma área de soja**. 2005. 133 p. (INPE 14219 TDI/1120). Dissertação de Mestrado - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2005.

GOMEZ, C.; VISCARRA ROSSEL, R. A.; MCBRATNEY, A. B. Soil organic carbon prediction by hyperspectral remote sensing and field Vis-NIR spectroscopy: An Australian case study. **Geoderma**, v. 146, n. 3-4, p. 403-411, 2008.

GREGO, C. R.; ARAUJO, L.; VICENTE, L. E.; NOGUEIRA, S. F.; MAGALHÃES, P. S. G.; VICENTE, A. K.; BRANCALIAO, S. R.; VICORIA, D. de C.; BOLFE, E. L. Agricultura de precisão em cana-de-açúcar. BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. p. 442-457, 2014.

HANSEN, P. M.; SCHJOERRING, J. K. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. **Remote Sensing of Environment**, 2003.

HEEGE, H. J.; REUSCH, S. Sensor for on the go control of site specific nitrogen top dressing. **ASAE Paper**, v. 961018, 1996.

HEEGE, H. J.; REUSCH, S.; THIESSEN, E. Prospects and results for optical systems for site-specific on-the-go control of nitrogen-top-dressing in Germany. **Precision Agriculture**, v. 9, n. 3, p. 115-131, 2008.

HOLLAND, K. H.; SCHEPERS, J. S. Derivation of a variable rate nitrogen application model for in-season fertilization of corn. **Agronomy Journal**, v. 102, n. 5, p. 1415-1424, 2010.

HOLLAND, K. H.; LAMB, D. W.; SCHEPERS, J. S. Radiometry of proximal active optical sensors (AOS) for agricultural sensing. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 5, n. 6, p. 1793-1802, 2012.

IBGE – Instituto Brasileiro de Geografia e Estatística. Levantamento Sistemático da Produção Agrícola (LSPA) Disponível em: <
<http://www.sidra.ibge.gov.br/bda/acervo/acervo9.asp?e=c&p=LA&z=t&o=26>>. Acesso em: 14 jun. 2016.

INAMASU, R.Y.; SOUSA, R.V.; PORTO, A.J.V.; FORTES, C.; LUCHIARI, A.; SCHEPERS, J.S.; SHANAHAN, J.F.; FRANCIS, D.D. Acesso ao estado nutricional da cana-de-açúcar por meio de sensor ativo de refletância. In: Congresso Brasileiro de Agricultura de Precisão, 2., 2006, São Pedro. **Anais**. Piracicaba: ESALQ, 2006. CD-ROM.

IZNAGA, A. C.; RODRÍGUEZ OROZCO, M.; AGUILA ALCANTARA, E.; CARRAL PAIROL, M.; DÍAZ SICILIA, Y. E.; DE BAERDEMAEKER, J.; SAEYS, W. Vis/NIR spectroscopic measurement of selected soil fertility parameters of Cuban agricultural Cambisols. **Biosystems Engineering**, v. 125, p. 105–121, 2014.

JARRELL, W.M.; BEVERLY, R.B. The dilution effect in plant nutrition studies. **Advances in Agronomy**, v.34, p.197-224, 1981.

JENSEN, J. R. **Remote sensing of the environment: An earth resource perspective**. Pearson Education India, 2009.

JESUS, P. H. H.; GALVANIN, E. S. Método semiautomático para extração e regularização de talhões de cana-de-açúcar utilizando imagens LANDSAT-5, classificador paralelepípedo e algoritmo de Douglas- Peuker; **Revista Ciência e Engenharia**, p. 49-56, 2013.

JOHNSON, G.V.; RAUN, W.R. Nitrogen response index as a guide to fertilizer management. **Journal of Plant Nutrition**, v. 26, n. 2, p. 249-262, 2003.

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).

KITCHEN, N. R.; SUDDUTH, K. A.; DRUMMOND, S. T.; SCHARF, P. C.; PALM, H. L.; ROBERTS, D. F.; VORIES, E. D. Ground-based canopy reflectance sensing for variable-rate nitrogen corn fertilization. **Agronomy Journal**, v. 102, n. 1, p. 71-84, 2010.

KURIHARA, C. H.; MAEDA, S.; ALVAREZ V, V. H. Interpretação de resultados de análise foliar. **Embrapa Agropecuária Oeste. Documentos**, 2005.

LEE, W. S.; EHSANI, R. Sensing systems for precision agriculture in Florida. **Computers and Electronics in Agriculture**, v. 112, p. 2-9, 2015.

LYRA, W. da S.; SILVA, E. C. da; ARAÚJO, M. C. U. de; FRAGOSO, W. D.; VERAS, G. Periodic classification : A didactic example to teach principal component analysis. **Química nova**, v. 33, n. 7, p. 1594–1597, 2010.

LOFTON, J., TUBANA, B.S.; KANKE, Y.; TEBOH, J.; VIATOR, H.; DALEN, M. Estimating sugarcane yield potential using an in-season determination of normalized difference vegetative index. **Sensors**, v. 12, n. 6, p. 7529-7547, 2012.

MARETTO, D. A. **Aplicação de máquinas de vetores de suporte para desenvolvimento de modelos de classificação e calibração multivariada em espectroscopia no infravermelho**. 2011. 133p. Tese (Doutorado em Química Analítica) – Universidade Estadual de Campinas, Instituto de Química, Campinas, 2011.

MALAVOLTA, E.; VITTI, G.C.; OLIVEIRA, S.A. **Avaliação do estado nutricional das plantas: princípios e aplicações**. (Ed.). Piracicaba: Associação Brasileira para pesquisa da Potassa e do Fósforo, 1997. 319p.

MANLY, B.J.F. **Métodos estatísticos multivariados: uma introdução**. 3.ed. Porto Alegre: Bookman, 2008. 229p

MARTINS, J. A. **Dados hiperespectrais para predição do teor foliar de nitrogênio em cana-de-açúcar**. 2016. 65 p. Tese (Doutorado) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2016.

MILAGRES, F. R.; GOMIDE, J. L.; MAGATON, A.; NETO, H. F. The influence of the age on near infrared spectroscopy models to prediction of the Eucalyptus spp. wood properties. **Revista Árvore**, v. 37, p. 1165–1173, 2013.

MIPHOKASAP, P.; HONDA, K.; VAIPHASA, C.; SOURIS, M.; NAGAI, M. Estimating canopy nitrogen

concentration in sugarcane using field imaging spectroscopy. **Remote Sensing**, v. 4, n. 6, p. 1651–1670, 2012.

MOLIN, J. P.; FRASSON, F. R.; AMARAL, L. R.; POVH, F. P.; SALVI, J. V. Capacidade de um sensor ótico em quantificar a resposta da cana-de-açúcar a doses de nitrogênio. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, n.12, p.1345-1349, 2010.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. **Agricultura de precisão**. São Paulo: Oficina de Textos, 2015.

MONTEIRO, P. F. C.; ÂNGULO FILHO, R.; MONTEIRO, R. O. C.; ADAMI, M.; MOREIRA, M. A. Aplicação da técnica da remoção do contínuo para a discriminação espectral de diferentes doses de Nitrogênio e lâminas de irrigação aplicadas à cultura do feijão (*Phaseolus vulgaris* L.) **Simpósio Brasileiro de Sensoriamento Remoto**, v. 25 - 30, p. 301-308, 2009.

MULLA, D. J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, n. 4, p. 358–371, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.biosystemseng.2012.08.009>>.

MÜLLER, K.; BÖTTCHER, U.; MEYER-SCHATZ, F.; KAGE, H. Analysis of vegetation indices derived from hyperspectral reflection measurements for estimating crop canopy parameters of oilseed rape (*Brassica napus* L.). **Biosystems Engineering**, v. 101, n. 2, p. 172–182, 2008.

NANNI, M.R.; DEMATTÊ, J.A.M. Spectral reflectance Methodology in Comparison to Traditional Soil Analysis. **Soil Science Society of America Journal**, v.70, p.393-407, 2006.

NASCIMENTO, J. A.; DIONÍSIO, A. G. G.; do NASCIMENTO, E. C. L.; BARBOSA, S. K. Análise screening de vinhos empregando um analisador fluxo-batelada, espectroscopia UV-VIS e quimiometria. **Química Nova**, v. 33, n. 2, p. 351-357, 2010.

NOVO, E. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Blucher, 2010.

OLIVEIRA, L. F.; SCHARF, P. C.; VORIES, E. D.; DRUMMOND, S. T.; DUNN, D.; STEVENS, W. G.; BRONSON, K. F.; BENSON, N. R.; HUBBARD, V. C.; JONES, A. S. Calibrating canopy reflectance sensors to predict optimal mid-season nitrogen rate for cotton. **Soil Science Society of America Journal**, v. 77, n. 1, p. 173-183, 2013.

PENATTI, C. P. **Adubação da cana-de-açúcar: 30 anos de experiência**. Itu (SP): Ottoni Editora, 2013.

PETERSON, D. L.; RUNNING, S. W. "Applications in Forest Science and Management" in **Theory and Applications of Optical Remote Sensing**. Nova York: John Wiley, p. 4210-4273, 1989.

PONZONI, F.J.; SHIMABUKURO, Y.E.; KUPLICH, T.M. **Sensoriamento remoto da vegetação**. 2ª edição. São Paulo, 2012

POVH, Fabricio Pinheiro. **Utilização de sensor ótico ativo em culturas de cereais**. 86 p. Dissertação (Mestrado) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2007.

PORTZ, G.; MOLIN, J.P.; JASPER, J. Active crop sensor to detect variability of nitrogen supply and biomass on sugarcane fields. **Precision Agriculture**, v. 13, n. 1, p. 33–44, 2012a.

PORTZ, G.; AMARAL, L.R.; MOLIN, J.P.; JASPER, J. Optimum sugarcane growth stage for canopy reflectance sensor to predict biomass and nitrogen uptake. In: **Proceedings of 10th International Conference on Precision Agriculture, Indianapolis, USA (CD-ROM)**. 2012b.

RAIJ, B. V.; CANTARELLA, H.; QUAGGIO, J. A.; FURLANI, A. M. C. **Recomendações de adubação e calagem para o Estado de São Paulo**. Campinas, Brazil: Instituto Agrônomo/Fundação IAC, 1997.

RAIJ, B. V. Fertilidade do solo e manejo de nutrientes. Piracicaba. **International Plant Nutrition Institute**. 420p, 2011.

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**, v. 94, n. 4, p. 815-820, 2002.

RAUN, W., SOLIE, J., STONE, M., MARTIN, K., FREEMAN, K., MULLEN, R., et al. Optical sensor-based algorithm for crop nitrogen fertilization. **Communications in Soil Science and Plant Analysis**, v. 36, n. 19-20, p. 2759-2781, 2005.

RIPOLI, T. C. C. **Plantio de cana-de-açúcar: estado da arte**. 216 p., 2007.

ROY R. N; FINCK A.; BLAIR G.J.; TANDON H.L.S. Plant nutrition for food security - A guide for integrated nutrient management. **FAO Fertilizer and Plant Nutrition**, Boletim 16, FAO, Rome, 2006

ROZANE, D. E.; PRADO, R. de M.; ROMUALDO, L. M.; PANCELLI, M. A.; FRANCO, C. F. Amostragem de folha em cana-de-açúcar submetida à adubação nitrogenada. **Revista de agricultura**, v. 83, n. 1, p. 8-18, 2008.

SANTOS, C. **Estatística descritiva-manual de auto-aprendizagem**. Lisboa: Edições Sílabo, 2007.

SANTOS, V. R. dos; MOURA FILHO, G.; ALBUQUERQUE, A. W. de; COSTA, J. P. V. da; SANTOS, C. G. dos; SANTOS, A. C. I. dos. Crescimento e produtividade agrícola de cana-de-açúcar em diferentes fontes de fósforo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 4, p. 389-396, 2009.

SAYES, W.; MOUAZEN, A.M.; RAMON, H. Potential for on site and online analysis of pig manure using visible and near infrared reflectance spectroscopy. **Biosystems Engineering**, v.91, p.393-402, 2005.

SAWYER, J. E. Concepts of variable rate technology with considerations for fertilizer application. **Journal of Production Agriculture**, v. 7, n. 2, p. 195-201, 1994.

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

SHI, Z.; WANG, Q.; PENG, J.; JI, W.; LIU, H.; LI, X.; ROSSEL, R.A.V. Development of a national VNIR soil-spectral library for soil classification and prediction of organic matter concentrations. **Science China Earth Sciences**, v. 57, n. 7, p. 1671- 1680, 2014.

SMITH, M.O.; JOHNSON, P.E.; ADAMS, J.B. Quantitative determination of mineral types and abundances from reflectance spectra using principal components analyses. **Journal of Geophysical Research**, v. 90, p. C797-C804, 1985.

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

SOUZA, E. G. de; SCHARF, P. C.; SUDDUTH, K. A. Sun position and cloud effects on reflectance and vegetation indices of corn. **Agronomy journal**, v. 102, n. 2, p. 734-744, 2010.

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

STROPPIANA, D.; BOSCHETTI, M.; BRIVIO, P. A.; BOCCHI, S. Plant nitrogen concentration in paddy rice from field canopy hyperspectral radiometry. **Field Crops Research**, v. 111, n. 1-2, p. 119-129, 2009.

SUDDUTH, K. A.; DRUMMOND, S. T.; KITCHEN, N. R. Operational characteristics of commercial crop canopy sensors for nitrogen application in maize. **Precision agriculture**, v. 15, p. 51-58, 2015.

TAGEEVA, S. V.; BRANDT, A. B.; DEREVYANKO, V. S. Changes in the optical properties of leaves during the growing season. **Doklady Akademii nauk SSSR**, v. 135, n. 5, p. 1270-3, 1960.

TOBIAS, R. D. **An Introduction to Partial Least Squares Regression**. SAS Institute Inc., 1995.

TODD, S. W., HOFFER, R. M., AND MILCHUNAS, D. G. Biomass estimation on grazed and ungrazed rangelands using spectral indices. **International Journal of Remote sensing**, 19, 427-438. 1998.

THENKABAIL, P. S., SMITH, R. B., DE PAUW, E. T. Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. **Remote sensing of Environment**, v. 71, n. 2, p. 158-182, 2000.

THENKABAIL, P. S., LYON, J. G., HUETE, A. Hyperspectral remote sensing of vegetation and agricultural crops: knowledge gain and knowledge gap after 40 years of research. **Hyperspectral remote sensing of vegetation**, p. 705, 2010

THOELE, H.; EHLERT, D. Biomass related nitrogen fertilization with a crop sensor. **Applied Engineering in Agriculture**, v. 26, n. 5, p. 769-775, 2010.

THORBURN, P.J., BIGGS, J.S.; WEBSTER, A.J.; BIGGS, I.M. An improved way to determine nitrogen fertiliser requirements of sugarcane crops to meet global environmental challenges. **Plant and Soil**, v. 339, n. 1-2, p. 51-67, 2011.

URQUIAGA, S.; CRUZ, K. H. S.; BODDEY, R. M. Contribution of nitrogen fixation to sugar cane: Nitrogen-15 and nitrogen balance estimates. **Soil Science Society America Journal**, v. 56, p. 105-114, 1992.

VARMUZA, K.; FILZMOSER, P. **Introduction to Multivariate Statistical Analysis in Chemometrics**. Boca Raton, Florida: CRC Press, 2009. 336p.

VISCARRA ROSSEL, R.A. "ParLeS: Software for chemometric analysis of spectroscopic data." **Chemometrics and intelligent laboratory systems**, v.90, p.72-83, 2008.

VISCARRA ROSSEL, R. A.; McBRATNEY, A. B. Laboratory evaluation of a proximal sensing technique for simultaneous measurement of soil clay and water content. **Geoderma**, v. 85, n. 1, p. 19-39, 1998.

VISCARRA ROSSEL, R. A.; WALVOORT, D. J. J.; McBRATNEY, A. B.; JANIK, L. J.; SKJEMSTA, J. O. Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. **Geoderma**, v. 131, n. 1-2, p. 59-75, 2006.

VISCARRA ROSSEL, R. A.; BEHRENS, T. Using data mining to model and interpret soil diffuse reflectance spectra. **Geoderma**, v. 158, n. 1-2, p. 46-54, 2010.

VISCARRA ROSSEL, R. A.; ADAMCHUK, V. I.; SUDDUTH, K. A.; McKENZIE, N. J.; LOBSEY, C. Proximal soil sensing: an effective approach for soil measurements in space and time. **Advances in Agronomy**, v. 113, p. 237-282, 2011.

VITTI, G. C.; MAZZA, J. A. Planejamento, estratégias de manejo e nutrição da cultura de cana-de-açúcar. **Piracicaba: Potafos**, v. 169, 2002.

VITTI, A. C. **Adubação nitrogenada da cana-de-açúcar (soqueira) colhida mecanicamente sem a queima prévia: Manejo e efeito na produtividade**. 2003. 114 f. Tese (Doutorado)-Centro de Energia Nuclear na Agricultura, Universidade de São Paulo, Piracicaba, 2003

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**, v. 31, p. 491-498, 2007.

XUE, L., LI, G.; QIN, X.; YANG, L.; ZHANG, H. Topdressing nitrogen recommendation for early rice with an active sensor in south China. **Precision Agriculture**, v. 15, n. 1, p. 95-110, 2014.

WETTERLIND, J.; STENBERG, B.; SÖDERSTRÖM, M. The use of near infrared (NIR) spectroscopy to improve soil mapping at the farmscale. **Precision Agriculture**, v. 9, n. 1, p. 57-69, 2008.

WOLD, S., MARTENS, H., WOLD, H. The multivariate calibration method in chemistry solved by the PLS method. In: Ruhe, A., Kagstrom, B. (Eds.), Proc. Conf. Matrix Pencils, Lecture Notes in Mathematics. Springer-Verlag, Heidelberg, pp. 286-293, 1983.

WOLD, S.; SJÖSTRÖM, M.; ERIKSSON, L. PLS-regression: a basic tool of chemometrics. **Chemometrics and Intelligent Laboratory Systems**, v. 58, p. 109-130, 2001.

WRIGHT, D.L.; RASMUSSEN, V.P.; RAMSEY, R.D.; BAKER, D.J.; ELLSWORTH, J.W. Canopy reflectance estimation of wheat nitrogen content for grain protein management. **GIScience and Remote Sensing**, v. 41, n. 4, p. 287-300, 2004.

APÊNDICES

APÊNDICE A. Estatística descritiva e teste de normalidade dos conjuntos de dados de TFN, altura e das regiões espectrais do azul, verde, vermelho, *red-edge* e infravermelho próximo, obtidos em cada uma das coletas, assim como, a estatística descritiva e teste de normalidade para a produtividade final.

(continua)

	Estatística Descritiva									
	Mín.	Máx.	Amp (¹)	Média	EPM (²)	Desvio	CV (%) ⁽³⁾	Assim. ⁽⁴⁾	Curt. ⁽⁵⁾	Shapiro
Produtividade (Mg ha ⁻¹)	62,76	105,29	42,52	93,93	1,73	8,99	9,57	-1,67	3,19	0,89
----- 67 DAC (Coleta 1) -----										
TFN (g kg ⁻¹)	10,89	24,93	14,04	17,37	0,46	2,45	14,12	0,32	2,34	0,93
Altura (cm)	83,80	111,80	28,00	99,21	1,41	7,44	7,50	-0,24	-0,89	0,97
Azul (%)	2,59	4,36	1,77	3,50	0,08	0,42	11,86	-0,03	-0,23	0,97
Verde (%)	4,59	7,77	3,17	6,44	0,13	0,70	10,95	-0,57	0,76	0,94
Vermelho (%)	4,17	7,05	2,88	5,21	0,15	0,82	15,72	0,56	-0,92	0,92
<i>Red-edge</i> (%)	8,17	13,39	5,22	11,40	0,21	1,13	9,87	-0,67	1,16	0,93
Infrav. próx. (%)	20,17	39,65	19,48	31,12	0,69	3,68	11,82	-0,43	1,64	0,94
----- 99 DAC (Coleta 2) -----										
TFN (g kg ⁻¹)	6,69	12,89	5,73	10,42	0,32	1,68	16,10	-0,32	-1,06	0,95
Altura (cm)	148,60	194,20	45,60	171,84	1,98	10,46	6,08	-0,01	-0,40	0,98
Azul (%)	2,89	4,94	2,05	3,85	0,13	0,69	17,88	0,23	-1,69	0,87
Verde (%)	5,55	9,09	3,54	7,19	0,22	1,17	16,29	0,21	-1,74	0,85
Vermelho (%)	3,72	8,34	4,62	5,32	0,23	1,22	22,91	0,48	-0,83	0,92
<i>Red-edge</i> (%)	10,05	16,16	6,11	12,98	0,38	2,01	15,46	0,23	-1,64	0,88
Infrav. próx. (%)	33,26	51,05	17,80	41,96	0,88	4,66	11,10	0,05	-0,79	0,98
----- 144 DAC (Coleta 3) -----										
TFN (g kg ⁻¹)	9,20	15,69	5,73	13,14	0,34	1,79	13,61	-0,75	-0,75	0,89
Altura (cm)	216,00	267,00	51,00	240,93	2,88	15,23	6,32	-0,13	-1,31	0,95
Azul (%)	2,87	3,91	1,04	3,36	0,05	0,24	7,12	-0,12	-0,19	0,97
Verde (%)	5,99	7,72	1,73	6,86	0,09	0,47	6,90	-0,25	-0,79	0,96
Vermelho (%)	3,61	6,75	3,15	4,47	0,12	0,61	13,69	1,63	4,41	0,85
<i>Red-edge</i> (%)	11,13	13,81	2,69	12,41	0,15	0,80	6,43	-0,04	-1,07	0,96
Infrav. próx. (%)	32,65	50,01	17,36	43,59	0,84	4,45	10,20	-0,81	0,02	0,93
----- 164 DAC (Coleta 4) -----										
TFN (g kg ⁻¹)	11,91	18,20	5,73	14,84	0,28	1,48	9,99	-0,17	-0,30	0,96
Altura (cm)	228,60	295,20	66,60	268,71	3,13	16,56	6,16	-0,40	-0,46	0,97
Azul (%)	2,73	3,43	0,70	3,07	0,03	0,17	5,63	0,07	-0,48	0,98
Verde (%)	5,65	7,07	1,43	6,27	0,06	0,33	5,26	0,23	-0,15	0,98
Vermelho (%)	3,52	6,00	2,48	4,37	0,11	0,59	13,40	1,28	1,02	0,86
<i>Red-edge</i> (%)	10,58	13,04	2,47	11,60	0,11	0,56	4,81	0,41	0,04	0,96
Infrav. próx. (%)	30,32	41,97	11,65	38,05	0,57	3,02	7,94	-0,78	-0,07	0,93

APÊNDICE A. Estatística descritiva e teste de normalidade dos conjuntos de dados de TFN, altura e das regiões espectrais do azul, verde, vermelho, *red-edge* e infravermelho próximo, obtidos em cada uma das coletas, assim como, a estatística descritiva e teste de normalidade para a produtividade final.

(conclusão)

	Estatística Descritiva									
	Mín.	Máx.	Amp ⁽¹⁾	Média	EPM ⁽²⁾	Desvio	CV ⁽³⁾ (%)	Assim. ⁽⁴⁾	Curt. ⁽⁵⁾	Shapiro
----- 200 DAC (Coleta 5) -----										
TFN (g kg ⁻¹)	11,14	16,87	5,73	14,06	0,27	1,44	10,27	0,03	-0,61	0,98
Altura (cm)	264,00	326,00	62,00	301,82	2,59	13,68	4,53	-0,59	0,37	0,96
Azul (%)	2,58	3,91	1,34	3,27	0,08	0,40	12,21	-0,02	-1,40	0,95
Verde (%)	5,79	8,48	2,70	6,96	0,15	0,81	11,63	0,13	-1,37	0,94
Vermelho (%)	3,69	6,15	2,47	4,88	0,12	0,64	13,20	0,15	-1,01	0,97
<i>Red-edge</i> (%)	11,04	16,07	5,04	13,29	0,29	1,53	11,49	0,08	-1,35	0,94
Infrav. próx. (%)	31,27	54,59	23,32	44,85	1,14	6,03	13,45	-0,55	-0,79	0,94
----- 228 DAC (Coleta 6) -----										
TFN (g kg ⁻¹)	10,37	15,54	5,17	12,65	0,26	1,35	10,71	0,35	-0,92	0,96
Altura (cm)	292,00	358,00	66,00	331,43	2,70	14,28	4,31	-0,69	0,30	0,96
Azul (%)	2,05	4,55	2,50	3,02	0,16	0,83	27,35	0,74	-1,07	0,84
Verde (%)	4,48	10,38	5,90	6,63	0,35	1,83	27,56	0,81	-0,92	0,84
Vermelho (%)	3,06	7,09	4,03	4,28	0,21	1,10	25,70	1,06	0,06	0,86
<i>Red-edge</i> (%)	8,74	18,14	9,39	12,20	0,53	2,79	22,86	0,80	-0,85	0,86
Infrav. próx. (%)	28,63	55,04	26,41	40,06	1,38	7,32	18,27	0,62	-0,93	0,90
----- 255 DAC (Coleta 7) -----										
TFN (g kg ⁻¹)	9,81	15,85	6,03	12,75	0,31	1,65	12,96	0,24	-0,93	0,97
Altura (cm)	321,00	373,00	52,00	354,11	2,43	12,83	3,62	-0,60	-0,21	0,96
Azul (%)	2,17	2,99	0,81	2,66	0,04	0,22	8,42	-0,53	-0,86	0,94
Verde (%)	4,85	6,70	1,84	5,97	0,10	0,51	8,49	-0,61	-0,67	0,94
Vermelho (%)	3,22	5,23	2,02	4,06	0,08	0,44	10,73	0,38	0,29	0,98
<i>Red Edge</i> (%)	9,42	12,84	3,42	11,53	0,18	0,93	8,09	-0,61	-0,68	0,94
Infrav. próx. (%)	30,75	41,88	11,14	36,69	0,64	3,41	9,30	-0,20	-1,44	0,93

Valores em negrito apresentaram $W_{\text{calculado}} < W_{\text{tabelado}}$ no teste de Shapiro-Wilk a um nível de significância de 1%, indicando que a amostra não provém de uma população normal;

⁽¹⁾ Amplitude;

⁽²⁾ Erro padrão da média;

⁽³⁾ Coeficiente de variação;

⁽⁴⁾ Assimetria;

⁽⁵⁾ Curtose.

APÊNDICE B. Estatística descritiva e teste de normalidade das variáveis após serem submetidas à transformação de dados.

Estatística Descritiva										
	Mín.	Máx.	Amp ⁽¹⁾	Média	EPM ⁽²⁾	Desvio	CV ⁽³⁾ (%)	Assim. ⁽⁴⁾	Curt. ⁽⁵⁾	Shapiro
----- 99 DAC (Coleta 2) -----										
Azul (%)	-16,92	-10,98	5,94	-13,75	0,37	1,94	14,13	0,06	-1,67	0,89
Verde (%)	-13,43	-8,29	5,14	-10,70	0,32	1,67	15,59	0,08	-1,72	0,87
Red-edge (%)	-6,94	-4,28	2,66	-5,49	0,16	0,85	15,39	0,07	-1,63	0,89
----- 144 DAC (Coleta 3) -----										
Vermelho (%)	-328,46	-96,65	231,81	-225,20	9,65	51,08	22,68	-0,03	0,04	0,97
----- 164 DAC (Coleta 4) -----										
Vermelho (%)	-1720,88	-453,6	1267,28	-1068,5	54,75	289,69	27,11	0,28	-0,15	0,96
----- 228 DAC (Coleta 6) -----										
Azul (%)	-257,27	-75,09	182,18	-160,24	10,61	56,16	35,05	0,15	-1,17	0,93
Verde (%)	-99,05	-24,48	74,58	-59,17	4,12	21,80	36,85	0,15	-1,06	0,93
Vermelho (%)	-387,89	-78,75	309,14	-236,91	16,93	89,56	37,80	0,16	-1,13	0,96
Red-edge (%)	-52,80	-12,86	39,94	-31,37	2,14	11,35	36,17	0,14	-1,08	0,94

Valores em negrito apresentaram $W_{\text{calculado}} < W_{\text{tabelado}}$ no teste de Shapiro-Wilk a um nível de significância de 1%, indicando que a amostra não provém de uma população normal;

(1) Amplitude;

(2) Erro padrão da média;

(3) Coeficiente de variação;

(4) Assimetria;

(5) Curtose.

APÊNDICE C. Precipitação observada e média da série histórica de 30 anos (precipitação normal) para o período em que foram realizadas as coletas de campo.

APÊNDICE D. Gráficos com a distribuição das parcelas em função dos escores das componentes principais 1 e 2 obtidos de sua resposta espectral (à esquerda) e gráficos dos autovetores da análise de componentes principais (à direita) (continua).

● Baixo teor de N foliar
● Médio teor de N foliar
● Alto teor de N foliar

— CP 1 — CP 2

APÊNDICE D. Gráficos com a distribuição das parcelas em função dos escores das componentes principais 1 e 2 obtidos de sua resposta espectral (à esquerda) e gráficos dos autovetores da análise de componentes principais (à direita) (conclusão).

APÊNDICE E. Estatística descritiva do TFN de cada agrupamento gerados nas diferentes coletas e para todos os dados agrupados (Geral).

Estatística descritiva	TFN em cada agrupamento classificado pelo teor de N								
	Baixo	Médio	Alto	Baixo	Médio	Alto	Baixo	Médio	Alto
	----- Geral ⁽²⁾ -----			--- 67 DAC (Coleta 1) ---			--- 99 DAC (Coleta 2) ---		
Média	11,10	13,91	16,86	14,75	17,37	19,97	8,74	11,04	12,33
Desvio	1,30	0,71	1,77	1,73	0,47	2,06	0,86	0,37	0,32
CV ⁽¹⁾	11,69	5,09	10,47	11,71	2,73	10,33	9,83	3,33	2,57
Mínimo	6,69	12,68	15,18	10,89	16,66	18,59	6,69	10,37	12,01
Máximo	12,89	15,13	24,93	16,17	18,16	24,93	9,79	11,61	12,89
Nº amostras	80	92	52	8	12	8	12	8	8
	--144 DAC (Coleta 3) --			--164 DAC (Coleta 4) --			--200 DAC (Coleta 5) --		
Média	10,20	12,61	14,36	12,85	15,06	16,89	12,66	14,35	16,10
Desvio	0,60	0,23	0,37	0,80	0,50	0,78	0,79	0,34	0,57
CV ⁽¹⁾	5,87	1,79	2,56	6,22	3,29	4,60	6,25	2,34	3,56
Mínimo	9,20	12,21	13,64	11,91	14,14	16,24	11,14	13,85	15,34
Máximo	10,82	12,84	15,69	14,00	15,69	18,20	13,41	14,87	16,87
Nº amostras	6	6	16	7	16	5	11	11	6
	-- 228 DAC (Coleta 6) --			-- 255 DAC (Coleta 7) --					
Média	11,16	12,56	14,24	11,03	12,85	15,03			
Desvio	0,33	0,40	0,74	0,64	0,40	0,62			
CV ⁽¹⁾	2,97	3,18	5,17	5,76	3,13	4,14			
Mínimo	10,37	12,15	13,41	9,81	12,21	14,38			
Máximo	11,54	13,23	15,54	11,82	13,57	15,85			
Nº amostras	9	10	9	10	11	7			

⁽¹⁾ Coeficiente de variação;

⁽²⁾ Análise aplicada aos dados agrupados de todas as coletas.

APÊNDICE F. Dez comprimentos de onda com melhor coeficiente de correlação com o TFN e as regiões espectrais a que pertencem para cada coleta e para todos os dados agrupados (Geral).

Geral			67 DAC (Coleta 1)			99 DAC (Coleta 2)		
Região espectral	Comp. de Onda (nm)	Correl.	Região espectral	Comp. de Onda (nm)	Correl.	Região espectral	Comp. de Onda (nm)	Correl.
Red-edge	720	-0,26	Azul	400	0,32	Infrav. Próx.	785	0,26
Red-edge	721	-0,26	Azul	419	0,26	Infrav. Próx.	802	0,26
Red-edge	724	-0,26	Azul	401	0,24	Infrav. Próx.	794	0,26
Infrav. Próx.	893	-0,25	Infrav. Próx.	900	0,20	Infrav. Próx.	780	0,26
Red-edge	719	-0,25	Infrav. Próx.	899	0,20	Infrav. Próx.	781	0,26
Infrav. Próx.	897	-0,25	Azul	420	0,19	Infrav. Próx.	795	0,26
Red-edge	723	-0,25	Infrav. Próx.	896	0,18	Infrav. Próx.	816	0,26
Red-ddge	718	-0,25	Infrav. Próx.	895	0,18	Infrav. Próx.	779	0,26
Red-ddge	722	-0,25	Azul	433	0,18	Infrav. Próx.	790	0,26
Infrav. Próx.	898	-0,25	Infrav. Próx.	863	0,17	Infrav. Próx.	789	0,26

144 DAC (Coleta 3)			164 DAC (Coleta 4)			200 DAC (Coleta 5)		
Região espectral ⁽¹⁾	Comp. de Onda (nm)	Correl.	Região espectral ⁽¹⁾	Comp. de Onda (nm)	Correl.	Região espectral ⁽¹⁾	Comp. de Onda (nm)	Correl.
Infrav. Próx.	807	0,63	Azul	400	0,66	Vermelho	671	-0,53
Infrav. Próx.	796	0,63	Azul	401	0,65	Vermelho	677	-0,53
Infrav. Próx.	806	0,63	Vermelho	675	-0,52	Vermelho	684	-0,53
Infrav. Próx.	812	0,63	Vermelho	674	-0,52	Vermelho	678	-0,52
Infrav. Próx.	813	0,63	Vermelho	676	-0,52	Vermelho	676	-0,52
Infrav. Próx.	795	0,63	Vermelho	679	-0,51	Vermelho	683	-0,52
Infrav. Próx.	797	0,63	Vermelho	670	-0,51	Vermelho	672	-0,52
Infrav. Próx.	786	0,63	Vermelho	671	-0,51	Vermelho	675	-0,52
Infrav. Próx.	805	0,63	Vermelho	680	-0,51	Vermelho	674	-0,52
Infrav. Próx.	802	0,63	Vermelho	690	-0,50	Vermelho	680	-0,52

228 DAC (Coleta 6)			255 DAC (Coleta 7)		
Região espectral ⁽¹⁾	Comp. de Onda (nm)	Correl.	Região espectral ⁽¹⁾	Comp. de Onda (nm)	Correl.
Infrav. próx.	760	-0,10	Azul	403	0,31
Infrav. próx.	777	-0,10	Azul	402	0,31
Infrav. próx.	759	-0,10	Azul	417	0,29
Infrav. próx.	778	-0,10	Azul	420	0,25
Infrav. próx.	788	-0,10	Azul	404	0,25
Infrav. próx.	761	-0,10	Azul	428	0,24
Infrav. próx.	776	-0,10	Azul	405	0,23
Infrav. próx.	779	-0,10	Azul	418	0,23
Infrav. próx.	782	-0,10	Azul	416	0,23
Infrav. próx.	781	-0,10	Azul	432	0,22

Valores de correlação em negrito indicam coeficiente de correlação significativo com nível de significância inferior a 0,05;

⁽¹⁾ Regiões espectrais às quais os comprimentos de onda selecionados pertencem.