**UNIVERSIDADE FEDERAL DO CEARÁ**
**CENTRO DE CIÊNCIAS AGRÁRIAS**
**DEPARTAMENTO DE ENGENHARIA AGRÍCOLA**
**PROGRAMA DE PÓS - GRADUAÇÃO EM ENGENHARIA AGRÍCOLA/**
**IRRIGAÇÃO E DRENAGEM**

**DAVID DE HOLANDA CAMPELO**

# USO DO SENSORIAMENTO REMOTO PARA DIAGNÓSTICO NUTRICIONAL NA CULTURA DO MILHO IRRIGADO

**FORTALEZA**

**2018**

DAVID DE HOLANDA CAMPELO

# USO DO SENSORIAMENTO REMOTO PARA DIAGNÓSTICO NUTRICIONAL NA CULTURA DO MILHO IRRIGADO

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, da Universidade Federal do Ceará, como parte dos requisitos para obtenção do título de Doutor em Engenharia Agrícola. Área de concentração: Irrigação e Drenagem.

Orientador: Prof. Adunias dos Santos Teixeira, Ph.D.

FORTALEZA

2018

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

C196u Campelo, David de Holanda.
Uso do sensoriamento remoto para diagnóstico nutricional na cultura do milho irrigado / David de Holanda Campelo. – 2018.
195 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Agrícola, Fortaleza, 2018.
Orientação: Prof. Dr. Adunias dos Santos Teixeira.
Coorientação: Prof. Dr. Luis Clenio Jário Moreira .

1. Agricultura de presição. 2. Hiperespectral. 3. Índice de nutrição. 4. PLSR. 5. Zea mays L.. I. Título.
CDD 630

---

DAVID DE HOLANDA CAMPELO

USO DO SENSORIAMENTO REMOTO PARA DIAGNÓSTICO NUTRICIONAL NA CULTURA DO MILHO IRRIGADO

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, da Universidade Federal do Ceará, como parte dos requisitos para obtenção do título de Doutor em Engenharia Agrícola. Área de concentração: Irrigação e Drenagem.

Orientador: Prof. Adunias dos Santos Teixeira, Ph.D.

Aprovado em: 25/04/2018

BANCA EXAMINADORA

Prof. Adunias dos Santos Teixeira, Ph.D. (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Luis Clenio Jário Moreira (Coorientador)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Prof. Dr. Flávio Jorge Ponzoni
Instituto Nacional de Pesquisas Espaciais - INPE

Prof. Dr. Claudivan Feitosa de Lacerda
Universidade Federal do Ceará (UFC)

Prof. Dr. Fernando Bezerra Lopes
Universidade Federal do Ceará (UFC)

Prof.ª Dr.ª Francisca Lígia de Castro Machado
Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Dedico este trabalho à toda minha família e em especial meus pais Joaquim Reinaldo e Maria das Graças, que me trouxeram com todo o amor e carinho a este mundo, me deram a vida e me ensinaram a vivê-la com dignidade. Vocês são o que eu tenho de mais precioso nessa vida.

## AGRADECIMENTOS

A Universidade Federal do Ceará – UFC, pela seriedade com que assume a função de ensinar.

Ao programa de Pós-graduação em Engenharia Agrícola, pela oportunidade concedida para estudar e aprimorar meus conhecimentos;

A Coordenação do Programa de Pós-Graduação em Engenharia Agrícola pelo apoio prestado durante a realização deste curso, assim como ao corpo docente pelos conhecimentos transmitidos;

A CAPES pela concessão da bolsa de estudo durante o curso;

Ao Professor Dr. Adunias dos Santos Teixeira, orientação e confiança em mim depositada, meu respeito e admiração;

Ao Dr. Luis Clenio Jário Moreira, pela grande contribuição que deu para que o trabalho fosse realizado e pelo grande amigo que se tornou minha sincera gratidão;

Aos Professores Claudivan Feitosa de Lacerda, Flávio Jorge Ponzoni, Fernando Bezerra Lopes e Francisca Lígia de Castro Machado, pela colaboração na banca examinadora. Obrigado por compartilhar seus conhecimentos;

A todos meus companheiros de trabalho do Laboratório de Eletrônica e Mecânica Agrícola (LEMA), em especial a Klenio Bezerra, Rômulo Uchoa, Vinícius Calou e Acrísio Feitosa, por todo o apoio e ajuda que deram e que fizeram com que exaustivos trabalhos se tornassem momentos de muita diversão e alegria;

Aos professores e demais amigos dos Departamentos de Ciências do solo e Fitotecnia, seria injusto citar o nome de um sem citar a todos, pelo companheirismo e bons momentos que levarei para sempre em minha memória.

A meus pais Joaquim Reinaldo, Maria das Graças, meus amados irmãos Jardel, Thenise e Holanda Neto, à minha namorada Micarla e toda família, que apesar de separados pela distância, é a base que me sustenta e mantém vivo, feliz e forte diante das adversidades da vida;

E enfim, a todos que contribuíram para a realização deste trabalho, seja de forma direta ou indireta, fica registrado aqui, o meu muito obrigado!

“A vida é maravilhosa se não se tem medo dela. ”
*Charles Chaplin*

**RESUMO**

A estimativa da condição nutricional de plantas a partir de sensores remotos pode contribuir para o monitoramento e à otimização do manejo de fertilizantes nas culturas agrícolas, proporcionando benefícios tanto agronômicos como ambientais. A concentração do nitrogênio (N) nas folhas é um importante indicador da sanidade das culturas agrícolas, desempenhando papel fundamental no metabolismo fotossintético e na nutrição das plantas. Assim, a quantificação do N é relevante para a previsão de produtividade e na melhoria do manejo de aplicação de fertilizantes. O sensoriamento remoto hiperespectral é uma técnica oportuna, promissora e de alto potencial de aplicação na agricultura em vários níveis de resolução espacial, para estimar, quantificar e monitorar atributos biofísicos e bioquímicos da vegetação. O presente trabalho teve como objetivo avaliar o potencial de aplicação de dados de SR no desenvolvimento de estratégias metodológicas para identificar deficiência nutricional e quantificar a concentração de nitrogênio (N) foliar em plantas de milho irrigado (*Zea mays* L.). Para tanto, duas estratégias experimentais foram executadas. Na primeira parte do estudo, foi montado um experimento com delineamento em blocos aleatorizados com esquema de parcelas subdivididas e quatro repetições. Os tratamentos de irrigação aplicados nas parcelas foram compostos de quatro níveis: 80, 90, 100 e 110% do requerimento hídrico, baseadas na capacidade de campo do solo e os níveis de N, distribuídos nas sub-parcelas foram: 0, 60, 120 e 180 kg $ha^{-1}$. Foram avaliados os componentes de produção e eficiências do uso de água (EUA) e N (EUN) assim como realizadas leituras espectrais em campo e laboratório e determinada a concentração de N foliar nos estádios V8, R1 e R3 da cultura nos níveis de campo e laboratório. Foram realizados dois ciclos de cultivo nos anos de 2015 e 2016. Os resultados indicaram que as lâminas de irrigação e doses de N influenciaram na altura de plantas e no índice de área foliar. A máxima produtividade foi alcançada na lâmina correspondente a 505 mm e dose de 180 kg $ha^{-1}$ de N, com rendimento de 17819,5 kg $ha^{-1}$. A maior EUA foi obtida em regimes de irrigação reduzida solo para 80 e 90 % do requerimento hídrico, enquanto que, a maior EUN (67,5 kg $kg^{-1}$) foi atingido com a lâmina 555,7 mm e dose 113,3 kg $ha^{-1}$ de N. Quanto a análise dos valores de fator de reflectância, as estratégias utilizadas para análise dos perfis de reflectância foram a análise derivativa (AD) e a análise de componentes principais (ACP). Os resultados evidenciaram regiões sensíveis às concentrações de N foliar, localizadas principalmente no visível na faixa entre 400 nm a 700 nm e no infravermelho próximo entre 800 nm a 1300 nm. O nível de coleta dos dados foi um

importante fator que influenciou no fator de reflectância em função dos tratamentos de adubação. Em laboratório, a região espectral compreendida entre 450 nm -750 nm, mostrou-se mais importante e em nível de campo a melhor resposta pode ser observada entre 800 nm e 1300 nm. A AD de primeira ordem identificou maiores variações em trono de duas regiões específicas 470 nm a 550 nm e 720 nm a 750 nm. A AD de segunda ordem, por sua vez, conseguiu evidenciar a faixa coincidente com a região de absorção dos pigmentos de clorofila entre 700 nm e 725 nm. A ACP mostrou que cerca de 90% e 95,12% do total da variação nos espectros pode ser explicada utilizando três componentes principais. Para dados de campo (dossel) o poder refletor ao longo de todo o espectro dominou a PC1. Para dados de laboratório (folha), a mesma PC1 sofre influência principalmente na faixa da borda vermelha (por volta de 700 nm) e ao longo de todo o infravermelho e parte do SWIR (750 nm a 2500 nm). A PC2 para os conjuntos de dados é distinguida principalmente entre as faixas 750 nm a 1300 nm, pelas cargas fatoriais, positivas para nível de folha e negativas para dossel. A PC3 é influenciada no visível, com picos máximos em torno de 550 nm e 750 nm em parte do SWIR em 1800 nm. Com os mesmos dados de espectroscopia, foi também averiguada a capacidade de gerar modelos preditivos que foram desenvolvidos usando regressões lineares de bandas individuais, índice normalizado de nitrogênio (NDNI) e regressão por mínimos quadrados parciais (PLSR). O N foliar foi precisamente quantificado, obtendo melhores resultados para modelos PLSR de laboratório no estádio R1 ($R^2$ = 0,82 e RMSEP = 0,190). Usando dados a nível de campo o melhor resultado foi obtido pelo NDNI (762 nm e 684 nm) para o estádio R3 ($R^2$ = 0,78 e RMSE = 0,200). A modelagem foi influenciada pelos estádios fenológicos e pelo nível de coleta de dados, o que reforça a importância do ajuste de modelos preditivos em função das diferentes fases de crescimento da cultura. Na segunda parte do estudo, foi investigado o potencial do uso de imagens hiperespectrais obtidos com o sensor aerotransportado ProSpecTIR-SV, para estimar de N foliar na cultura do milho em diferentes estádios de crescimento, visando avaliar o potencial dessa ferramenta no manejo da adubação. Amostras de N foliar do dossel de plantas foram coletadas em diferentes campos de cultivos de milho nos estádios vegetativo (1m) e reprodutivo (2m), durante o voo no primeiro semestre de 2015. O procedimento de seleção de bandas espectrais pelo método stepwise forward foi utilizado junto com a regressão por mínimos quadrados parciais (PLSR) para o desenvolvimento dos modelos. Os dados do estádio reprodutivo mostraram melhor performance na estimativa do N foliar ($R^2$= 0,844, RMSECV= 1,0114 e RPD = 2,388). O modelo misto (1m+2m) foi menos preciso em relação aos modelos individuais. O potencial

das imagens para a criação de mapas de fertilidade de N foi confirmado com precisão com RMSECV variando entre 1,014 e 2,082 g $Kg^{-1}$ N. Finalmente, a seleção de bandas juntamente com a PLSR é promissor para detecção de N foliar na cultura do milho.

**Palavras-chave**: Agricultura de precisão. Hiperespectral. Índice de nutrição. PSLR. *Zea mays* L.

**ABSTRACT**

The estimation of status plants nutritional from remote sensing can contribute to the monitoring and optimization of the management of fertilizers in the crops, providing both agronomic and environmental benefits. The concentration of leaf nitrogen (N) is an important indicator of crop health, playing a key role in the photosynthetic metabolism and plant nutrition. Thus, the quantification of N is relevant for predicting productivity and improving the management of fertilizer application. Hyperspectral remote sensing is a timely, promising technique with high application potential in agriculture at various levels of spatial coverage to estimate, quantify and monitor biophysical and biochemical attributes of vegetation. This study aimed to evaluate the potential application of SR development data methodological strategies to identify nutritional deficiency and quantify the concentration of leaf nitrogen (N) in irrigated maize (Zea mays L.). For that, two experimental strategies were executed. In the first part of the study, an experiment was set up with a randomized block design with subdivided plots and four replications. The irrigation treatments applied in the plots were composed of four levels: 80, 90, 100 and 110% of the water requirement, based on the soil field capacity and the nitrogen levels, distributed in the subplots at levels 0, 60, 120 and 180 kg ha-1. The production components and water use efficiency (US) and N (EUN) were evaluated, spectral readings were performed, and the concentration of leaf nitrogen at the V8, R1 and R3 stages of the crop at the field and laboratory levels was determined. Two cultivation cycles were carried out in the years 2015 and 2016. The results indicated that the irrigation slides and N doses influenced plant height and leaf area index. The maximum yield was reached the corresponding blade to 505 mm and 180 kg ha-1 C, in a yield of 17819.5 kg ha-1. The highest EUA was obtained in irrigation regimes reduced to 80 and 90% of the water requirement, while the highest EUN (67.5 kg kg-1) was reached with the as the 555.7 mm blade and level 113, 3 kg ha-1 of N. Regarding the spectral responses, the strategies used to analyze the reflectance profiles were derivative analysis (AD) and principal component analysis (PCA). The results evidenced sensitive regions of foliar N concentrations located mainly in the visible range in the range of 400 nm to 700 nm and near infrared between 800 nm and 1300 nm. The level of data collection was an important factor that influenced the spectral response as a function of fertilization treatments. In the laboratory, the regions between 450 nm-750 nm, are more important and at the field level the best response can be observed between 800 nm and 1300 nm. The first-order AD identified greater throne

variations of two specific regions 470 nm at 550 nm and 720 nm at 750 nm. The second order AD, in turn, was able to show the range coincident with the response of chlorophyll pigments between 700 nm and 725 nm. ACP showed that about 90% and 95.12% of the total variation in spectra can be explained using three major components. For field data (canopy) the reflecting power over the entire spectrum dominated PC1. For laboratory data (sheet), the same PC1 is influenced mainly in the red border range (around 700 nm) and throughout the infrared and part of the SWIR (750 nm at 2500 nm). The PC2 for the datasets is distinguished mainly between the bands 750 nm to 1300 nm, by factorial charges, positive for leaf level and negative for canopy. PC3 is influenced in the visible, with maximum peaks around 550 nm and 750 nm in part of the SWIR at 1800 nm. With the same spectroscopy data, the ability to generate predictive models that were developed using linear regressions of individual bands, normalized nitrogen index (NDNI) and partial least squares regression (PLSR) were also investigated. The leaf N was precisely quantified, obtaining better results for laboratory PLSR models in the R1 stage ($R^2$ = 0.82 and RMSEP = 0.190). Using field-level data the best result was obtained by the NDNI (762 nm and 684 nm) for the R3 stage ($R^2$ = 0.78 and RMSE = 0.200). Modeling was influenced by the phenological stages and level of data collection, which reinforces the importance of adjusting predictive models as a function of the different stages of crop growth. In the second part of the study, the potential of the use of hyperspectral images obtained with the ProSpecTIR-SV airborne sensor to estimate leaf N in corn at different stages of growth was investigated, in order to evaluate the potential of this tool in the management of fertilization. Samples of leaf N of the canopy of plants were collected in different fields of maize in the vegetative (1m) and reproductive (2m) stages during the first half of 2015. The stepwise forward spectral band selection procedure was used in conjunction with the partial least squares regression (PLSR) for the development of the models. Data from the reproductive stage showed a better performance in leaf N estimation ($R^2$ = 0.844, RMSECV = 1.0114 and RPD = 2.388). The mixed model (1m + 2m) was less accurate than the invidious models. The potential of the images for the creation of N fertility maps was accurately confirmed with RMSECV ranging from 1,014 to 2,082 g Kg-1 N. Finally, band selection along with PLSR is promising for leaf N detection in the crop of maize.

**Keywords**: Precision agriculture. Hyperspectral. Nutrition index. PSLR. *Zea mays* L.

## LISTA DE FIGURAS

Figura 1 - Esboço esquemático do método PLSR ..... 34
Figura 2 - Croqui da área experimental ..... 42
Figura 3 - Esquema da unidade experimental. ..... 43
Figura 4 - Dados pluviométricos ocorridos nos ciclos de cultivos: A) ciclo I e B) ciclo II. .. 44
Figura 5 - Altura de plantas (ALT) de milho submetidas a diferentes níveis de lâminas de irrigação em função da adubação nitrogenada, nos ciclos I (A) e II (B). ..... 49
Figura 6 - Índice de Área Foliar (IAF) em plantas de milho submetidas a diferentes níveis de lâminas de irrigação em função da adubação nitrogenada, nos ciclos I (A) e II (B) ..... 49
Figura 7 - Produtividade de espigas sem palha (PE) em plantas de milho submetidas a diferentes níveis de lâminas de irrigação em função da adubação nitrogenada, nos ciclos I (A) e II (B) ..... 50
Figura 8 - Eficiência do uso de Nitrogênio (EUN) em plantas de milho submetidas a diferentes níveis de lâminas de irrigação em função da adubação nitrogenada, nos ciclos I (A) e II (B) ..... 51
Figura 9 - Eficiência do uso de água (EUA) em função das lâminas de irrigação e doses de nitrogênio para o ciclo I (A e B) e II (C e D) ..... 52
Figura 10 - Aquisição de dados espectrais em laboratório ..... 65
Figura 11 - Espectros de reflectância coletados em laboratório em todos os estádios fenológicos para: (A) 2015 n=64 e (B) 2016 n=192. ..... 68
Figura 12 - Espectros de reflectância coletados em campo em todos os estádios fenológicos para: (A) 2015 n=192 e (B) 2016 n=128. ..... 69
Figura 13 – Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de folhas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R3 obtidas em laboratório no ciclo I (2015)..... 71
Figura 14 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de folhas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento V8 obtidas em laboratório no ciclo II (2016)..... 72
Figura 15 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de folhas de milho submetidos a diferentes níveis de adubação

nitrogenada no estádio de desenvolvimento R1 obtidas em laboratório no ciclo II (2016).....73
Figura 16 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de folhas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R1 obtidas em laboratório no ciclo II (2016).....74
Figura 17 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento V3 obtidas em campo no ciclo I (2015).....75
Figura 18 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R1 obtidas em campo no ciclo I (2015).....76
Figura 19 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R3 obtidas em campo no ciclo I (2015).....77
Figura 20 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento V8 obtidas em campo no ciclo II (2016). .....78
Figura 21 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R3 obtidas em campo no ciclo II (2016). .....79
Figura 22 - Variância explicada dos preditores X (A) e Autovalores (B) em função do número de componentes para dados de reflectância de folhas coletados em laboratório (n=256). .....81
Figura 23 - Variância explicada dos preditores X (A) e Autovalores (B) em função do número de componentes para dados de reflectância de folhas coletados em campo (n=320) .....81

Figura 24 - Peso de carregamento (*loadings)* (A) e Coeficientes *loadings* (B) para os três primeiros PCs em função do espectro de reflectância para os dados de laboratório. .....82
Figura 25 - Peso de carregamento (*loadings*) (A) e Coeficientes *loadings* (B) para os três primeiros PCs em função do espectro de reflectância para os dados de campo....83
Figura 26 - Fluxograma de procedimentos de obtenção dos modelos preditivos .....98
Figura 27 - Probabilidade de normalidade dos dados de concentração de nitrogênio foliar: (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016; (E) estádio R1 e (E) estádio R3 2016. .....99
Figura 28 - Concentração de N foliar (%) em função dos tratamentos em 2015 (Ciclo I). As barras indicam o erro padrão da média (n =4). .....100
Figura 29 - Concentração de N foliar (%) em função dos tratamentos em 2016 (Ciclo II). As barras indicam o erro padrão da média (n =4). .....101
Figura 30 - Correlação de Pearson (r) entre a concentração de N foliar e reflectância da folha para todas as bandas entre 350 nm e 2500 nm em condições de laboratório. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016. .....102
Figura 31 - Equações de calibração obtidas a partir da relação entre reflectância de bandas individuais e a concentração de N foliar. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016.....103
Figura 32 - Equações de validação obtidas a partir da relação entre reflectância de bandas individuais e a concentração de N foliar. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016.....104
Figura 33 - Correlação de Pearson (r) entre a concentração de N foliar e reflectância da folha para dados coletado em condições de campo. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016. .....105
Figura 34 - Equações de calibração obtidas a partir da relação entre reflectância de bandas individuais e a concentração de N foliar. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016. .....106
Figura 35 - Equações de validação obtidas a partir da relação entre reflectância de bandas individuais e a concentração de N foliar. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016. .....107

Figura 36 - Coeficiente de determinação entre todas as combinações de reflectância de bandas i e j usadas para obter NDNI e concentração de N foliar para o conjunto amostral de calibração de laboratório. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016. ..... 109
Figura 37 - Equações de calibração entre o melhor NDNI e a concentração de N foliar. (A) estádio R3 2015 ([922-505]/[922+505]); (B) estádio V8 2016 ([1182-529]/[1182+529]); (C) estádio R1 2016 ([910-690]/[910+690]) e (D) estádio R3 2016 ([738-733]/[738+733]) ..... 110
Figura 38 -. Equações de validação entre o melhor NDNI e a concentração de N foliar. (A) estádio R3 2015 ([922-505]/[922+505]); (B) estádio V8 2016 ([1182-529]/[1182+529]); (C) estádio R1 2016 ([910-690]/[910+690]) e (D) estádio R3 2016 ([738-733]/[738+733]) ..... 110
Figura 39 - Coeficiente de determinação entre todas as combinações de reflectância de bandas i e j usadas para obter NDNI e concentração de N foliar para o conjunto amostral de calibração de campo. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016. ..... 112
Figura 40 - Equações de calibração entre o melhor NDNI e a concentração de N foliar para dados de campo. (A) estádio V8 2015 ([722-622]/[722+622]); (B) estádio R1 2015 ([933-646]/[933+646]); (C) estádio R3 2015 ([716-715]/[716+715]); (D) estádio V8 2016 ([720-702]/[720+702]) e (E) estádio R3 2016 ([762-684]/[762+684]) ..... 113
Figura 41 - Equações de validação entre o melhor NDNI e a concentração de N foliar para dados de campo. (A) estádio V8 2015 ([722-622]/[722+622]); (B) estádio R1 2015 ([933-646]/[933+646]); (C) estádio R3 2015 ([716-715]/[716+715]); (D) estádio V8 2016 ([720-702]/[720+702]) e (E) estádio R3 2016 ([762-684]/[762+684]) ..... 114
Figura 42 - Resultados da calibração e validação cruzada dos modelos PLSR. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016 ..... 116
Figura 43 - Equações de validação entre os modelos PLSR e a concentração de N foliar para dados de laboratório. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016 ..... 116

Figura 44 - Resultados da calibração e validação cruzada dos modelos PLSR. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016. ..... 118
Figura 45 - Equações de validação entre os modelos PLSR e a concentração de N foliar para dados de campo. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016. ..... 119
Figura 46 - Localização da área de estudo ..... 132
Figura 47 - Perfis espectrais de dosséis de plantas de milho com o incremento da concentração de N foliar para os conjuntos de dados 1m (A) e 2m (B), obtidos do sensor ProSpecTIR-VS ..... 136
Figura 48 - Valores observados e previstos da concentração de N foliar (g $kg^{-1}$) dos modelos PLSR, para os conjuntos de dados de reflectância 1m (A) (n=36), 2m (B) (n=30) e todos os dados (n=66) (C). O coeficiente de determinação ($R^2$), erro quadrado médio da calibração (RMSEC) e validação cruzada (RMSECV) e valores preditivos residuais (RPD), respectivamente. ..... 139

## LISTA DE TABELAS

Tabela 1 – Estádios vegetativos e reprodutivos de uma planta de milho ..... 24
Tabela 2 – Descrição dos tratamentos de lâminas ..... 43
Tabela 3 – Parcelamento da adubação de nitrogênio. ..... 44
Tabela 4 – Médias e desvio padrão para as variáveis de Altura de plantas (ALT), Índice de área foliar (IAF), Produtividade de espigas (PE), eficiência do uso da água (EUA) e eficiência do uso de nitrogênio (EUN) para os tratamentos no ciclo I. ..... 47
Tabela 5 – Médias e desvio padrão para as variáveis de Altura de plantas (ALT), Índice de área foliar (IAF), Produtividade de espigas (PE), eficiência do uso da água (EUA) e eficiência do uso de nitrogênio (EUN) para os tratamentos no ciclo II. ..... 47
Tabela 6 – Resumo da análise de variância para as variáveis de altura de plantas (ALT), índice de área foliar (IAF), produtividade de espigas (PE), eficiência de uso da água (EUA) e de nitrogênio (EUN) para o ciclo I. ..... 48
Tabela 7 – Resumo da análise de variância para as variáveis de altura de plantas (ALT), índice de área foliar (IAF), produtividade de espigas (PE), eficiência de uso da água (EUA) e de nitrogênio (EUN) para o ciclo II ..... 48
Tabela 8 – Descrição dos tratamentos ..... 64
Tabela 9 – Descrição da coleta de dados espectrais ..... 67
Tabela 10 – Descrição dos tratamentos ..... 95
Tabela 11 – Estatísticas descritivas da calibração dos modelos PLSR (n =48) e validação (n =16) para conjunto de dados obtidos em laboratório ..... 115
Tabela 12 – Estatísticas descritivas da calibração dos modelos PLSR (n =48) e validação (n =16) para conjunto de dados obtidos em campo ..... 117
Tabela 13 – Características e parâmetros de aquisição das imagens. ..... 134
Tabela 14 – Estatísticas descritivas dos conjuntos de amostras de N foliar ..... 135

## LISTA DE ABREVIATURAS E SIGLAS

| | |
|---|---|
| AP | Altura da planta |
| BI | Banda individual |
| DNOCS | Departamento Nacional de Obras Contras Secas |
| EUA | Eficiência do uso de água |
| EUN | Eficiência do uso de nitrogênio |
| GPS | Global Positioning System |
| IAF | Índice de área foliar |
| nm | Nanômetro |
| N | Nitrogênio |
| ND | N° digital |
| NDNI | Índice normalizado de nitrogênio |
| NIR | infravermelho próximo |
| PC | componente principal |
| PE | Produtividade de espigas |
| PLSR | Regressão por Mínimos Quadrados Parciais |
| RMSE | Raiz do erro quadrático médio |
| RMSEP | Raiz do erro quadrático médio da predição |
| RMSEVC | Raiz do erro quadrático médio da validação cruzada |
| RPD | taxa de desvio da performance |
| SD | desvio padrão |
| SWIR | Infravermelho de ondas curtas |
| VIS | faixa espectral do visível |

## LISTA DE SÍMBOLOS

| | |
|---|---|
| $R^2$ | Coeficiente de determinação |
| $R^2$ajust. | Coeficiente de determinação ajustado |
| $R$ | Coeficiente de correlação de Pearson |
| $\lambda$ | Comprimento de onda |
| $\rho$ | Reflectância |
| ° | Graus |

**SUMÁRIO**


**1 INTRODUÇÃO GERAL** ..... 20

**2 REVISÃO DE LITERATURA** ..... 23

**3 FUNÇÃO DE RESPOSTA DO MILHO À ÁGUA E NITROGÊNIO EM CONDIÇÕES FERTIRRIGADAS** ..... 40

**4 RESPOSTA ESPECTRAL DO MILHO SUBMETIDO A DIFERENTES NÍVEIS DE IRRIGAÇÃO E ADUBAÇÃO NITROGENADA** ..... 60

**5 ANÁLISE QUANTITATIVA DE NITROGÊNIO NA CULTURA DO MILHO A PARTIR DA REFLECTÂNCIA** ..... 90

**6 ESTIMATIVA DA CONCENTRAÇÃO DE NITROGÊNIO EM DOSSÉIS DE MILHO ATRAVÉS DE IMAGENS HIPERESPECTRAIS** ..... 129

**7 CONSIDERAÇÕES FINAIS** ..... 153

**REFERÊNCIAS** ..... 156

**APÊNDICE A – TABELAS DAS ANÁLISES DE VARIÂNCIA** ..... 165

**APÊNDICE B - ESTATÍSTICAS DAS SUPERFÍCIES DE RESPOSTA** ..... 170

**APÊNDICE C - RESULTADOS DAS ANÁLISE FATORIAIS PARA OS MODELOS PLSR DO CAPÍTULO III** ..... 178

# 1 INTRODUÇÃO GERAL

A agricultura atualmente tem sido colocada diante da problemática do aumento da demanda na produção de alimentos. Nesse cenário, a produção agrícola tem exigido o máximo de tecnologias que resultem no aprimoramento das técnicas de cultivos e na eficiência de aplicação dos recursos.

O aumento de produtividade, diminuição de danos ambientais, segurança alimentar, e consequentemente, maior rentabilidade do processo produtivo, são algumas das vantagens da otimização do uso de insumos na produção agrícola de modo geral. O conceito de agricultura de precisão tem então sido atualmente inserido como uma forma de gerenciamento da produção agrícola, que atende demandas locais na lavoura, partindo de informações exatas sobre a variação espacial da necessidade de insumos.

A ampla demanda pelo emprego de agricultura de precisão é atualmente gerada pelas grandes culturas. A produção em larga escala exige extensas áreas de cultivos e os valores econômicos envolvidos em *commodities* como a do milho, da soja e do trigo, por exemplo, justificam a utilização desse tipo de gerenciamento. Dentre as grandes culturas anuais para produção de grãos, o milho está entre as mais cultivadas em nível mundial. Segundo dados da Organização das Nações Unidas para Alimentação e Agricultura - FAO (2018) a produção anual de milho em grãos superou o valor de 1 bilhão de toneladas em todo mundo, com área plantada em torno de 187 milhões de hectares. O Brasil é o terceiro maior produtor e segundo maior exportador mundial. Segundo dados da Companhia Nacional de Abastecimento - CONAB (2015) a produção na safra 2014/2015 foi de cerca de 80 milhões de toneladas, com área plantada de 9,33 milhões de hectares.

Pela importância econômica que apresenta, essa espécie é amplamente pesquisada em diversas áreas de estudo como melhoramento genético, tratos culturais, nutrição mineral e manejo da irrigação. O aperfeiçoamento de técnicas de cultivo como os de diagnose nutricional e estado hídrico das plantas é imprescindível para alcançar a produtividade desejável e economia de insumos envolvidos na produção, principalmente água e fertilizantes em geral.

Nesse sentido, atualmente dados provenientes de sensores remotos tem mostrado viabilidade para o monitoramento das condições nutricional e hídrica da vegetação. O estresse por deficiências nutricional e hídrica ocasiona mudanças significativas na fisiologia das plantas. A senescência foliar precoce e acelerada é uma das principais respostas induzidas nesses processos e é caracterizada por alterações biofísicas, bioquímicas e moleculares

específicas, principalmente a degradação de pigmentos fotossintetizantes como a clorofila. Essas alterações ocasionam, consequentemente, modificações na reflectância espectral que são passiveis de serem obtidas por diversos tipos de sensores. Assim, essas informações podem ser relacionadas com o conteúdo de constituintes bioquímicos das folhas, a exemplo do nitrogênio (N). Partindo-se desse princípio, modelos preditivos e índices de vegetação relacionados com a condição nutricional das plantas têm sido desenvolvidos, como o objetivo de gerenciar a aplicação de recursos das diversas culturas.

O que justifica o interesse em modelos e em índices estimadores da condição nutricional de plantas, além da utilização no manejo da adubação, é a possibilidade da previsão de produtividade. A previsão da safra dentro do gerenciamento da propriedade rural permite ao produtor antever as condições de compra e de venda e as variações no mercado, minimizando o risco de investimentos na atividade agrícola. Finalmente, a grande vantagem desses modelos e de índices é a possibilidade de utilização a partir de dados provenientes de sensores orbitais e aerotransportados obtidos na lavoura.

As aplicações dessas informações são de grande relevância na agricultura de precisão, sendo importante ferramenta para a tomada de decisões. A produtividade de diferentes áreas agrícolas pode ser estimada, permitindo ao produtor identificar determinados talhões que necessitem de melhorias na aplicação de insumos, ou seja, definir zonas de manejo diferenciado.

O mapa de produtividade materializa o rendimento da cultura com a melhor exatidão possível, considerando as tecnologias existentes para sua mensuração. Para tanto, as variáveis que afetam a produtividade precisam ser bem definidas e estabelecer relação com o rendimento da cultura.

A utilização de informações geradas a partir de sensoriamento remoto, no contexto da agricultura de precisão, ainda é pouco explorada nas áreas agrícolas do Estado do Ceará. As grandes áreas de exploração agrícola e o alto retorno econômico justificam a utilização dessa prática, que visa o aumento da produtividade e o uso racional de recursos garantindo maior lucratividade e a redução dos impactos ambientais.

Na literatura científica poucos trabalhos têm se dedicado a temática da agricultura de precisão nesta região, havendo a necessidade de estudos que considerem as demandas regionais, bem como, a divulgação do tema, uma vez que esse tipo de prática é pouco utilizado na região.

**Hipóteses**

A utilização de sensores capacitivos de umidade do solo é uma estratégia viável para o manejo adequado de água e, consequentemente, permite o melhor aproveitamento agronômico da adubação nitrogenada;

O fator de reflectância espectral possibilita a identificação e a diferenciação de plantas com estresse nutricional;

A utilização de dados de sensores hiperespectrais de reflectância permite a determinação do status de N da cultura do milho irrigado por meio da quantificação do nitrogênio foliar;

Imagens de sensores hiperespectrais são uma ferramenta viável para determinação do estado nutricional da cultura do milho irrigado.

**Objetivos da pesquisa**

O presente trabalho tem como objetivo geral o desenvolvimento de modelos preditivos para estimar o conteúdo de nitrogênio foliar em plantas de milho submetidas a diferentes disponibilidades hídricas e níveis de adubação nitrogenada a partir de dados de espectroscopia de reflectância e imagens hiperespectrais, possibilitando melhor compreensão das contribuições de dados espectrais para o diagnóstico nutricional da cultura do milho irrigado.

Como objetivos específicos:

- Avaliar a eficiência na utilização da água e do nitrogênio (N) na cultura do milho em função de diferentes níveis de irrigação e de adubação nitrogenada;
- Caracterizar espectralmente o efeito das variações de N foliar sobre as curvas de reflectância em plantas de milho por meio de espectroradiometria;
- Avaliar a utilidade dos dados de sensoriamento remoto hiperespectral oriundos de dosséis e de folhas isoladas de plantas de milho, no desenvolvimento de modelos preditivos para estimar nitrogênio foliar;
- Avaliar o desempenho do uso de imagens hiperespectrais para estimar a concentração de N foliar na cultura do milho e na criação de mapas de fertilidade em áreas agrícolas.

# 2 REVISÃO DE LITERATURA

## Caracterização morfofisiológica do milho (*Zea mays* L.)

### *Caracterização botânica*

O milho (*Zea mays* L.), é uma planta pertencente à família botânica das gramineae/poaceae, subfamília *Panicoidae*, gênero *Zea*, com origem aproximada em regiões da América Central, mais precisamente no México. O milho é uma cultura anual (entre 110 e 180 dias para condições de clima no Brasil) de alto rendimento e amplamente cultivada desde 58º de Latitude Norte no Canadá e na Rússia até os 40º de latitude sul na Argentina. (FORNASIERI FILHO, 2007).

Estruturalmente, a planta de milho é constituída por uma haste cilíndrica, com nós e entrenós compactos. O sistema radicular é constituído de raízes fasciculadas e o caule do tipo colmo. As folhas são inseridas nos nós presentes no colmo, dos quais se desenvolvem raízes adventícias bem como as espigas e os perfilhos. As folhas são consideradas estreitas, por ter comprimento superior à sua largura e são arranjadas alternadamente e são suportadas pela superposição de suas bainhas que envolvem o colmo. A bainha invaginante, pilosa de cor verde clara e limbo-verde escuro, estreito e de forma lanceolada, possuindo bordos serrilhados com uma nervura central vigorosa. (FORNASIERI FILHO, 2007)

O milho é uma planta monóica, ou seja, possui os órgãos masculinos e femininos na mesma planta em inflorescências diferentes. A inflorescência masculina é encontrada na extremidade superior do caule em um tipo de panícula que contém unicamente os estames envolvidos nas glumas e os femininos em ramificações laterais em espigas axilares. A floração ocorre normalmente entre os 50 e os 100 dias após a sementeira e é afetada principalmente pela temperatura. O milho é anemófilo, ou seja, a polinização se dá pela transferência do grão de pólen da antera da flor masculina para o estigma da flor feminina por meio de condições naturais, pelo vento. A autofecundação representa apenas cerca de 2%, caracterizando como uma planta de polinização cruzada. O grão é o fruto de uma semente ou cariopse, característico das gramíneas (BARROS, 2014).

***Estádios de desenvolvimento***

Os estádios de desenvolvimento caracterizam-se pelas mudanças morfofisiológicas identificáveis e representativas que ocorrem durante o ciclo da cultura (FORNASIERI FILHO, 2007). A descrição detalhada dos estádios comumente utilizados encontra-se na Tabela 1.

Tabela 1 - Estádios vegetativos e reprodutivos de uma planta de milho

| Estádios de desenvolvimento | |
|---|---|
| **Vegetativos** | **Reprodutivos** |
| VE – Emergência | R1 – florescimento |
| V1 – primeira folha | R2 – grão bolha d'água |
| V2 – segunda folha | R3 – grão leitoso |
| V3 – terceira folha | R4 – grão pastoso |
| V6 – sexta folha | R5 – grão farináceo |
| V9 – nona folha | R6 – maturidade fisiológica |
| V12 – décima segunda folha | |
| V15 – décima quinta folha | |
| V18 – décima oitava folha | |
| VT – Pendoamento | |

Fonte: Ritchie *et al.*, (2013).

Para identificação dos estádios de desenvolvimento da planta do milho adota-se, geralmente, a divisão em fase vegetativa (V) e reprodutiva (R). As subdivisões (estádios fenológicos) da fase vegetativa são designadas numericamente como V1, V2, V3, etc., até V (n), no qual (n) representa o estádio da última folha antes do pendoamento. O primeiro e o último estádios de V são designados como VE (emergência) e VT (pendoamento). O (n) pode variar de acordo com diferentes cultivares, época de semeadura, condições climáticas, estresses ambientais, entre outros. Cada estádio foliar é definido de acordo com a folha de inserção mais alta cuja aurícula seja visível. As subdivisões da fase reprodutiva são designadas numericamente em R1 (florescimento), R2 (grão bolha d'água), R3 (grão leitoso), R4 (grão pastoso), R5 (grão farináceo) e R6 (maturidade fisiológica), respectivamente (RITCHIE et al., 2013).

***Necessidades nutricionais***

As necessidades nutricionais das culturas são estabelecidas de acordo com a quantidade de nutrientes extraída durante o seu ciclo produtivo. As quantidades extraídas

dependem da produtividade atingida, do cultivar, das condições de clima, fertilidade do solo, adubação realizada e demais tratos culturais. Nesse sentido, a marcha de absorção constitui elementos fundamentais no manejo de adubação (VON PINHO *et al.*, 2010).

No milho a maioria dos nutrientes é extraída pelos grãos, folhas e colmo. Os elementos mais exigidos são o nitrogênio e potássio, seguido do magnésio, fósforo, o cálcio e o enxofre. Nos grãos, a ordem de absorção desses nutrientes é bastante alterada. O P é em sua maioria translocado para as sementes, seguindo-se do nitrogênio, o enxofre, o potássio, o magnésio e o cálcio. As necessidades nutricionais, e consequentemente, as taxas de absorção dos elementos podem ser alteradas em função dos estádios de desenvolvimento. No caso específico do N, esse apresenta papel importante no estádio inicial de desenvolvimento, quando a planta está com quatro folhas totalmente desdobradas (V4), influenciada principalmente pelo crescimento do sistema radicular. A fertilização de N nessa fase estimula a proliferação de ramificações das raízes e seus pelos absorventes, o que resulta no desenvolvimento da parte aérea. Nas fases seguintes o N tem papel fundamental no processo de diferenciação floral, o qual origina a panícula e a espiga. Além disso, o N atua na síntese da citocinina, fundamental para o sistema radicular da plântula do milho. A adubação nitrogenada geralmente aumenta o teor de proteína no grão e aumenta os componentes de produção na cultura (FORNASIERI FILHO, 2007).

**Técnicas de diagnose nutricional em plantas**

Atualmente as técnicas de diagnose nutricional de N em plantas comumente utilizadas baseiam-se na coleta em campo de material vegetal (folhas diagnósticas) e posterior análise química em laboratório. Os processos em laboratório envolvem a secagem em estufa de circulação forçada de ar á 60°C (até peso constante), seguida da solubilização das amostras por meio de digestão sulfúrica e a determinação do N total por destilação. O método mais usual é o semi-micro Kjeldahl. Essa técnica exige grande número de coletas para representar precisamente a demanda nutricional de uma determinada área, assim, em extensas regiões agrícolas pode se tornar inviável e ser considerada a principal desvantagem desse método. Além disso, a mão-de-obra para coleta e o tempo gasto em análise laboratorial reforçam a necessidade de métodos mais apropriados para esse fim e aplicáveis às diversas escalas produtivas. Recentemente métodos mais práticos como o medidor de clorofila portátil Soil-Plant Analysis Development (SPAD-502), têm sido utilizados como medida indireta do teor

de N em plantas, devido à alta correlação da clorofila com N (YANG *et al*., 2014). O funcionamento desse aparelho baseia-se na relação de medidas de transmitância em comprimentos de onda associados à clorofila: vermelho (650 nm) e infravermelho próximo (940 nm) (MINOLTA, 1989). Essa prática tem se mostrado viável para o monitoramento da condição nutricional em plantas, apresentando resultados semelhantes a índices de vegetação preditivos do teor de clorofila na cultura do milho (CASA *et al*., 2015).

Como alternativa, técnicas baseadas em sensoriamento remoto mostram-se promissoras para avaliação do teor de N em plantas. A espacialização de forma mais precisa de áreas com demandas nutricionais distintas e a aplicabilidade em larga escala, são as principais vantagens que podem ser citadas. Dados gerados a partir de sensores orbitais e sub-orbitais ou aerotransportados têm um grande potencial para a aplicação desse tipo de técnica (HOUBORG *et al*., 2009).

Para coleta de dados em campo, a espectrorradiometria é uma técnica imediata e precisa para o estudo das relações entre dados espectrais e dados biofísicos, e tem sido largamente utilizada nos trabalhos de pesquisa em sensoriamento remoto. A maior parte desses estudos aborda a dinâmica de espectros de fatores de reflectância. A maioria dos modelos e índices relacionados ao estado nutricional de plantas é desenvolvida entre as faixas de 480 nm a 1300 nm. Particularmente em regiões influenciadas por pigmentos fotossintéticos opticamente ativos e em pontos nos quais se verificam tendências opostas de reflexão e absorção da radiação eletromagnética por parte dos vegetais, entre 600 e 800 nm, faixa denominada na literatura com “borda vermelha” (CHEN *et al*., 2010; HUNT *et al*., 2013).

## Reflectância da vegetação

O sensoriamento remoto tem se mostrado uma técnica prática e não destrutiva para estimar características biofísicas da vegetação, com a vantagem de ser aplicável a diferentes escalas no processo produtivo agrícola. No caso específico de sua aplicação no estudo da vegetação, sua caracterização espectral pode ser feita em nível de folhas isoladas, de plantas isoladas e em conjuntos de plantas (dosséis) (PONZONI, 2007).

O comportamento espectral da vegetação é função de sua composição, morfologia e estrutura interna. Assim, as alterações nas características da folha causadas por diferentes fatores, tais com modificações na composição bioquímica, ocasionarão diferenças na reflectância.

Espectros de reflectância de folhas isoladas verdes sadias apresentam forma típica caracterizada em três regiões espectrais frequentemente exploradas: I) de 300 até 700 nm, na qual a reflectância é baixa (menor que 20%) e fortemente influenciada pelos pigmentos fotossintetizantes existentes na planta, principalmente clorofilas e carotenoides; II) entre 700 nm a 1300 nm, na qual a reflectância é relativamente alta ( entre 30% e 40%) devido ao espalhamento da REM que ocorre no mesófilo foliar; III) entre 1300 a 2500 nm, onde a reflectância é influenciada pelo conteúdo de água existente dentro das folhas (NOVO, 2010; LORENZZETTI, 2015).

**Estimativa da condição nutricional de plantas por sensoriamento remoto**

Para melhor compreensão de como os fatores de reflectância da REM incidente sobre uma folha podem ser utilizados para estimativa da condição nutricional é necessário o conhecimento de sua composição química, da sua estrutura celular e dos fatores que influenciam esses componentes na vegetação. As principais características de interesse são mudanças na quantidade de pigmentos fotossintetizantes e sua morfologia interna (PONZONI, 2007).

Entre os fatores modificadores da composição química na folha está a condição nutricional das plantas. Segundo Munné-bosch e Alegre (2004), o estresse por deficiência nutricional ocasiona mudanças significativas na fisiologia das plantas. A senescência foliar precoce e acelerada é a principal resposta induzida, caracterizada por alterações bioquímicas e moleculares específicas, principalmente a degradação da clorofila. Essas alterações ocasionam, consequentemente, modificações no espectro de reflectância. O principal nutriente responsável nesse processo é o N. A deficiência desse elemento induz mudanças na estrutura e na cor nas folhas (clorose), o que possibilita a identificação de padrões espectrais de resposta à adubação (CHEN *et al.*, 2010).

As alterações nas propriedades espectrais da vegetação ocasionadas por estresse nutricional servem de embasamento para a utilização de técnicas de sensoriamento remoto na diagnose e no manejo de nutrientes em culturas agrícolas. Esse tipo de abordagem tem sido investigada para aplicações em cultivos de larga escala como o milho (*Zea mays L.*) (SCHLEMMER *et al.*, 2013; QUEMADA *et al.*, 2014)

As faixas espectrais do visível (VIS) e infravermelho próximo (NIR) são as principais regiões onde se é possível à identificação das alterações na reflectância da

vegetação em função da adubação. No VIS as alterações devem-se principalmente a degradação de pigmentos, especialmente da clorofila, caracterizando a diminuição da intensidade da cor verde aos olhos humanos. As variações nas quantidades desses pigmentos influenciam fortemente na curva espectral de reflectância em plantas submetidas a diferentes disponibilidades de N (CILIA *et al.*, 2014). Uma mudança característica é o aumento da reflectância nessa região especifica do espectro, principalmente na faixa do verde (550 nm) e borda-vermelha (715 nm), ocasionado pelo aumento das quantidades de clorofila (DAUGHTRY *et al.*, 2000). Os padrões de relectância na região espectral do verde e a absorção próxima ao vermelho (670 nm) são amplamente explorados em estudos sobre deficiência de N em plantas (HUNT *et al.*, 2013).

A região do NIR é influenciada pela estrutura celular do mesófilo, no qual ocorre elevado espalhamento da radiação. Dessa forma, mudanças estruturas no tecido foliar devido a variações no suprimento nutricional, a exemplo da disponibilidade de N, tem efeito na reflectância nessa faixa espectral. Segundo Schlemmer *et al.* (2013), o crescimento foliar e o aumento de biomassa em plantas bem fertilizadas, interferem fortemente na reflectância no NIR. Especialmente, a nível de dossel, esse aumento na estrutura foliar é responsável pela maior dispersão da radiação eletromagnética incidente pelo dossel das plantas (HEEGE *et al.*, 2008)

Devido à forte ligação das alterações de reflectância com mudanças estruturais, o NIR tem grande potencial na previsão do rendimento das culturas. Quemada *et al.* (2014), utilizando dados de imagens hiperespectrais na diagnose nutricional do milho, constataram que curvas espectrais de reflectância apresentaram maior diferenciação em comprimentos de onda acima de 740 nm, mostrando maior sensibilidade nessa faixa a variáveis de concentração do N foliar.

A posição da borda vermelha, faixa entre (680-780 nm) tem sido utilizada como um dos principais parâmetros em plantas estressadas por deficiência nutricional. Em estudo com plantas de milho, Cho e Skidmore (2006) utilizaram um método de extrapolação linear para avaliar a reflectância em função da adubação nitrogenada. Esse método determina a intercessão de duas linhas retas da primeira derivada do espectro de reflectância no extremo vermelho (680 nm a 700 nm) e no NIR (725 a 760 nm). Os resultados mostraram alta sensibilidade desse método com a concentração de N foliar em comparação com outros métodos de interpolação tradicionais, como polinomial e técnicas de ajuste gaussiano na utilização de dados dos sensores AVIRIS, HyMap e Hyperion. Ainda para cultura do milho,

Cleversa e Gitelsonb (2013), constataram por meio do coeficiente de variação do espectro de reflectância, que as bandas centradas em 724 e 800 nm foram mais eficientes para descrever alterações na borda vermelha em função de mudanças no N foliar.

A reflectância de um dossel pode ainda ser influenciada pela sua arquitetura. Diker e Bausch (2003) constataram que o índice de área foliar (IAF) de plantas de milho com distribuição angular planófila geralmente são mais elevados que as que apresentam dossel erectófilo. Essa diferença altera a reflectância do dossel e ocasiona diferença em índices de vegetação. Segundo Gitelson *et al.* (2002), a orientação vertical da folha aumenta a absorção da radiação pelo dossel, e, portanto, diminuindo a reflectância no NIR. Huemmrich (2013) utilizaram o modelo SAIL para simular a reflectância em um dossel contendo algumas camadas com diferentes distribuições angulares de folha, e descobriu que a variação da angulação em cada camada afetada a fração de radiação fotossinteticamente ativa absorvida.

Outro fator que interfere na reflectância da vegetação é a fase de crescimento. Mudanças na cobertura foliar e efeitos de fundo devem ser considerados nos diferentes estágios de desenvolvimento do milho (LI *et al.* 2014), segundo esses autores, o efeito do solo dificulta a diferenciação na reflectância de plantas em diferentes níveis de suprimento de N. Quemada *et al.* (2014), salientam que essa dificuldade na diferenciação ocasiona baixo desempenho de índices estimadores de N na fase vegetativa na cultura do milho e enfatiza a importância de previsões no crescimento inicial da cultura, com o intuído de manejar a adubação nitrogenada.

As alterações nos conteúdos de constituintes bioquímicos foliares são fatores consideráveis na reflectância da vegetação. A senescência e a mudança na composição de pigmentos são processos graduais que variam ao longo do ciclo de desenvolvimento da vegetação. Geralmente maiores concentrações de clorofila são observadas na fase de crescimento em relação à reprodutiva. Essa mudança ocorre também entre as folhas. Na fase inicial na cultura do milho a maioria das folhas da planta tem alto conteúdo de clorofila, enquanto na fase reprodutiva as folhas na parte inferior estão em avançado processo de senescência com baixo teor de clorofila. Assim, durante esses dois estádios de desenvolvimento a quantidade de radiação absorvida dentro do dossel é diferente (GITELSON *et al.*, 2014). Considerando essa variação Shaver *et al.* (2011), verificaram nos estádios finais do crescimento vegetativo (V12 a V14), os melhores resultados na diferenciação da variabilidade de N em plantas de milho irrigado. Recentemente, Xia *et al.* (2016) identificaram nas fases (V7 a V10), a melhor precisão no diagnostico em taxas de

suprimento variáveis. A partir desse estádio, o fechamento do dossel e o aumento de biomassa tendem a saturar os índices de vegetação como o NDVI. Esse problema pode ser resolvido com a utilização de índices relativos como o RVI. Nesse caso, o efeito da diluição do N em relação à biomassa foliar deve ser considerado na estimativa de N em plantas de milho.

**Sensoriamento remoto hiperespectral**

Com o advento de novas tecnologias de sensoriamento remoto baseado na aquisição de dados hiperespectrais, uma grande variedade de índices espectrais associados à diferentes parâmetros funcionais e biofísicos das plantas tem sido desenvolvidos. As informações espectrais em diversos comprimentos permitem melhor identificação de diferentes tipos de alvo e uma maior precisão na construção de índices de bandas curtas relacionados ao status nutricional de plantas (LI *et al*., 2014).

Recentemente, modelos preditivos de características biofísicas gerados a partir de dados hiperespectrais têm sido desenvolvidos e sugeridos para a cultura do milho. Estudos em nível de campo e através de sensores aerotransportados mostram resultados promissores na utilização de imagens de alta resolução espectral na criação de mapas de fertilidade baseadas no estado nutricional da planta (QUEMADA *et al*., 2014). O maior nível de detalhamento espectral possibilita a aplicação de índices específicos, como de conteúdo de N foliar, resultando em ferramenta valiosa para gestão adequada na utilização de fertilizantes (CILIA *et al*., 2014). A quantificação do N é o tema relevante em estudos sobre a avaliação nutricional de plantas por meio de sensoriamento remoto e tem atraído grande número de pesquisas sobre o assunto. A deficiência desse elemento induz mudanças na estrutura e na cor nas folhas (clorose), o que possibilita a identificação de padrões espectrais de resposta à adubação (CHEN *et al*., 2010).

Em outros tipos de aplicações, a análise de regiões específicas do espectro de reflectância tem mostrado resultados satisfatórios na diferenciação de estágios de senescência foliar ligados ao estresse por seca, possibilitando a detecção remota da condição hídrica (BEHMANN *et al*., 2013). Segundo Benedetto *et al*. (2013), essas informações, conjuntamente com técnicas de geoestatística, podem ser utilizadas na delimitação de zonas homogêneas em relação a sanidade de plantas. A aplicabilidade desses tipos dados em diferentes tipos de cobertura vegetal (pastagem, arbustiva e floresta) é demostrada por Casas

*et al*., (2014) utilizando dados obtidos pelo sensor AVARIS (*Advanced Visible Infrared Imaging Spectrometer*).

## Técnicas multivariadas de análise de dados hiperespectrais

### *Análise de componentes principais*

A Análise por componentes principais (ACP) é uma abordagem interessante para análise da resposta espectral de reflectância da vegetação. A principal função dessa ferramenta é reduzir a dimensionalidade dos dados espectrais e extrair as características mais importantes das variáveis (YANG *et al.*, 2016). A PCA reduz o conjunto de dados originais em variáveis transformadas, ou componentes principais - CP, que são obtidos por uma combinação linear dos dados originais que são ortogonais, baseados na variância total, e que apresentam elevado poder de explicação (BRO; SMILDE, 2014). Essa transformação é conduzida de tal forma que o primeiro PC consegue captar a maior variação possível, e cada componente subsequente, por sua vez, possui a maior variação possível sob a restrição de que é ortogonal aos componentes anteriores (LIU *et al.*, 2017).

Na ACP, são obtidos os autovalores, também conhecido como raiz latente, que representa a quantia de variância explicada por um fator ou componente e os autovetores, que indicam as variáveis de entradas mais importantes para explicar cada componente. Na análise de dados hiperespectrais, as componentes podem ser selecionadas a partir da análise do diagrama de sedimentação ou *scree plot* (gráfico de declive) dos autovalores e variância explicada. Os pesos de carregamento (*loadings*) e os seus respectivos coeficientes das PCs selecionadas, comumente são utilizados para analisar a contribuição da explicação da reflectância nos diferentes comprimentos de onda em cada componente selecionada. Os *loadings* e seus coeficientes fornecem a composição das PCs em relação às bandas espectrais (variáveis X), permitindo compreender a influência de cada um dos PCs para descrever o espectro.

A possibilidade do detalhamento da análise da resposta espectral torna a PCA um método estático largamente utilizado em estudos da vegetação (LIU *et al.*, 2017; SUN *et al.*, 2017). Nesse sentido, estudos têm usado a PCA para identificar os atributos mais importantes e que explicam a variação da resposta espectral da reflectância da vegetação e sua relação com variáveis bioquímicas foliares (YANG *et al.*, 2016; LIU *et al.*, 2017). Dessa forma,

consegue-se reduzir o número de variáveis sem perda considerável de informações contidas no conjunto de dados originais, permitindo analisar conjuntamente um grande número de bandas espectrais. Além disso, apresenta a vantagem de contornar o problema da multicolinearidade, que é um fator inerente aos dados hiperespectrais (MIRZAIE *et al.*, 2014).

***Regressão por mínimos quadrados parciais (PLSR)***

A análise de regressão é uma técnica estatística cujo escopo é investigar e modelar a relação entre variáveis. As técnicas de regressão são largamente utilizadas em trabalho envolvendo dados de sensoriamento remoto. Esse método baseia-se na relação funcional entre duas variáveis e a determinação da função que expressa esse relacionamento.

Considerando que exista um relacionamento funcional entre os valores Y e X e admitindo ser uma reta a linha teórica de regressão, a função entre X e Y é a seguinte:

$$\mathbf{y} = \alpha + \beta\mathbf{X} + e \qquad (1)$$

Em que, Y é a variável dependente, X é a variável independente, α e β são os coeficientes do modelo e *e* denota os erros ou resíduos da regressão.

Frequentemente, os pontos observados apresentarão uma variação em torno da linha da função de regressão, devido à existência de uma variação aleatória adicional denominada de variação residual. Partindo-se do princípio do método de regressão para obtenção do ajuste de uma reta, um dos procedimentos mais adequados é a aplicação do método dos mínimos quadrados, segundo o qual a reta a ser adotada deverá ser aquela que torna mínima a soma dos quadrados dos erros ou resíduos da regressão. A expressão mais comum para o somatório dos resíduos é:

$$Q=(ri)= \sum_{i=1}^{n} ri^2 \qquad (2)$$

em que, ri é o resíduo.

Assim, o método dos mínimos quadrados consiste em minimizar o somatório dos quadrados dos desvios entre o valor observado e o valor estimado, procurando funções lineares entre as variáveis que explicam a variação de tal erro (NAGHETTINI; PINTO, 2007)

No caso particular de uma análise multivariada, para um conjunto de dados em que se deseja estabelecer uma relação linear entre *m* vaiáveis dependentes, para uma variável y considera-se a função ajuste como:

$$\mathbf{y=b_0 + b_1x_1+b_2\ x_2+\ldots+\ b_mx_m+e} \qquad (3)$$

Em que, **xi** são variáveis independentes e **y** é a variável dependente, $\boldsymbol{b_i}$ são constantes parciais de regressão, ***e*** é o erro residual.

O procedimento de determinar os coeficientes que minimizam o somatório dos erros pode ser convenientemente descrito em notação matricial. Nesse caso, para uma base de dados com ***k*** variáveis explicativas e ***n*** observações, o modelo pode ser expresso como:

$$\begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ \ldots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{21} & \ldots & x_{k1} \\ 1 & x_{12} & x_{22} & \ldots & x_{k2} \\ 1 & x_{13} & x_{23} & \ldots & x_{k3} \\ \ldots & \ldots & \ldots & \ldots & \ldots \\ 1 & x_{1n} & x_{12} & \ldots & x_{kn} \end{pmatrix} \times \begin{pmatrix} b_1 \\ b_2 \\ b_3 \\ \ldots \\ y_k \end{pmatrix} + \begin{pmatrix} e_1 \\ e_2 \\ e_3 \\ \ldots \\ e_n \end{pmatrix} \qquad (4)$$

Em que, $\boldsymbol{x_{ji}}$ é o valor da j-ésima variável da i-ésima observação. Assim, a equação pode ser simplificada para:

$$\mathbf{Y=XB+e} \qquad (5)$$

O processo de minimização da dos erros na função da equação 2 pode ser resolvido de acordo com a seguinte expressão:

$$\mathbf{B}=Y\cdot X^{-1} \qquad (6)$$

Em que, **B** é matriz de transformação, **Y** é o vetor de variáveis dependentes e **X** é o vetor de variáveis independentes.

Segundo Fuhry (2011), o problema pode ser resolvido por meio técnicas de operações matriciais com a utilização da matriz transposta **X´**:

$$\mathbf{B} = [\,X'\,X]^{-1}X'\,Y \qquad (7)$$

O *Partial Least Squares Regression* (PLSR) é um método amplamente indicado para a construção de modelos de previsão quando se tem um elevado número de fatores, altamente colineares. Dessa forma, é considerada uma prática útil, quando o objetivo é a necessidade de limitar o número de fatores medidos. A aplicação dessa metodologia é bastante utilizada em dados de espectroscópicos (TOBIAS ,1995)

Em uma abordagem multivariada, embora exista elevado número de fatores correlacionado com a variável resposta, muito desses fatores podem ser fatores subjacentes ou latentes, que representam a maior parte da variação dos dados. A ideia geral da PLSR é tentar extrair esses fatores latentes, representando o máximo de variação quanto possível. Isto é conseguido através da extração de variáveis latentes T e U de fatores incluídos na amostra e respostas, respectivamente (FIGURA 1).

Figura 1 - Esboço esquemático do método PLSR

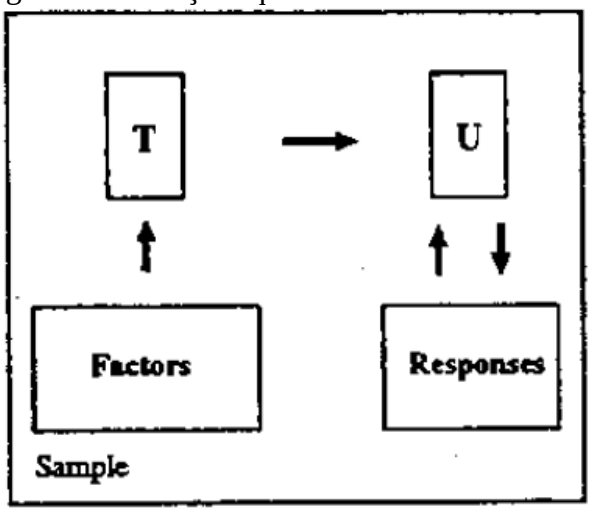


Fonte: Adaptada de Tobias (1995).

Os fatores **T** extraídos (designados como X-scores) são usados para prever **Y**-scores **U**, e, em seguida os **Y**-scores preditos são utilizados para construir previsão para variável resposta. Na PLSR o **X** e **Y**-scores são escolhidos de modo que a relação entre os pares sucessivos de pontuações é tão forte quanto possível.

A PLSR é extensamente utilizada em dados de sensoriamento remoto em geral. A possibilidade de analisar conjuntamente grande número de bandas espectrais, suas fontes de variação e a resolução do problema da colinearidade entre elas, são as principais vantagens desse método. Uma das abordagens mais utilizadas é a redução do número de variáveis, visando a melhoria do desempenho do modelo, melhorando a interpretação e diminuindo

custos computacionais e reduzindo a complexidade do modelo. Além disso, a seleção de variáveis pode ser relevante para reduzir o risco de *overfitting*, ou superjuste dos dados (ANDERSEN; BRO, 2010).

Segundo Atzberger *et al.* (2010), a PLSR fornece um modelo de regressão, onde toda a informação espectral é analisada de forma ponderada, dessa forma, esse método mostra-se adaptado para lidar com fatores de confusão na construção de índices de vegetação. Além disso, é particularmente bem adaptado para a calibração de um pequeno número de amostras. Nesse trabalho, os autores utilizaram a PLSR para selecionar bandas espectrais na composição de um índice estimador de clorofila na cultura do trigo. A PLSR mostrou melhor eficiência na predição e menor sensibilidade a ruído em comparação aos métodos *Principal component regression* (PCR) e *Stepwise multiple linear regression* (SMLR).

Em um tipo de aplicação mais específica, a PLSR tem sido utilizada na obtenção de informações espectrais ligadas a parâmetros bioquímicos e biofísicos da vegetação, que incluem a seleção de bandas para composição de índices de vegetação e potencialidade de uso em imagens hiperespectrais. Ryu *et al.* (2011), com objetivo de estimar o conteúdo de N na cultura do arroz, verificaram que a PLSR forneceu melhores estimativas em relação a *Multiple linear regression* (MLR) para dados hiperespectrais, sobretudo, pela maior sensibilidade do modelo selecionado às variações de N. As semelhanças e diferenças de pesos de carga (scores) para cada modelo em relação a reflectância pode ter afetado os coeficientes de regressão e a precisão de cada modelo. Para a PRSL a variação de N explicada foi de 81% com quatro variáveis latentes. Mirzaie *et al*. (2014), utilizou a PLSR para estimar o conteúdo de água na folha de quatro diferentes tipos de plantas. O PLSR forneceu melhores estimativas em relação a utilização dos índices de bandas estreitas relacionados com o conteúdo de água na vegetação, como o *ratio water index* (RWI) e o *normalized difference water index* (NDWI), mostrando alto potencial do uso dessa técnica como ferramenta no mapeamento de variáveis biofísicas a partir de dados hiperespectrais. Segundo Feilhauer *et al.* (2015), a PLSR pode ser otimizada para seleção de bandas espectrais especificas relacionadas a componentes bioquímicos como clorofila, conteúdo de água e matéria seca. O conjunto de bandas selecionadas incluem informações refinadas que permitem a definição de regiões do espectro de acordo com o coeficiente de absorção de cada componente de maneira mais robusta. A PRSL pode ainda ser utilizada na seleção de comprimentos de onda que melhor representaram uma determinada faixa do espectro.  A seleção da combinação ótima de bandas, de forma

individual, como do verde, do vermelho e do infravermelho, melhoram a precisão de índices como o NDVI para predição de variáveis bioquímicas (HANSEN e SCHJOERRING, 2003)

## REFERÊNCIAS


ANDERSEN, C. M.; BRO, R. Variable selection in regression—a tutorial. **Journal of Chemometrics**, v. 24, n. 11-12, p. 728-737, 2010.

ATZBERGER, C.; GUÉRIF, M.; BARET, F.; WERNER, W. Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat. **Computers and Electronics in Agriculture**, v. 73, n. 2, p. 165-173, 2010.

BEHMANN, J.; STEINRÜCKEN, J.; PLÜMER, L. Detection of early plant stress responses in hyperspectral images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.93, p.98–111, 2014.

BARROS, José FC; CALADO, José G. **A cultura do milho**. 2014. <http://hdl.handle.net/10174/10804>**.** Acesso 22 de março de 2018.

BENEDETTO, D.; CASTRIGNANO, A.; DIACONO, M.; RINALDI, M.; RUGGIERI, S.; TAMBORRINO, R. Field partition by proximal and remote sensing data fusion. **Biosystems Engineering**, v.114, n.4, p.372-383, 2013.

BRO, R.; SMILDE, A. K. Principal component analysis. **Analytical Methods**, v. 6, n. 9, p. 2812-2831, 2014.

CASA, R.; CASTALDI, F.; PASCUCCI, S.; PIGNATTI, S. Chlorophyll estimation in field crops: an assessment of handheld leaf meters and spectral reflectance measurements. **The Journal of Agricultural Science**, v. 153, n. 05, p. 876-890, 2015.

CASAS, A.; RIAÑO, D.; USTIN, S. L.; DENNISON, P.; SALAS, J. Estimation of water-related biochemical and biophysical vegetation properties using multitemporal airborne hyperspectral data and its comparison to MODIS spectral response. **Remote Sensing of Environment**, v.148, p.28-41, 2014.

CHEN, P.; HABOUDANE, D.; TREMBLAY, N.; WANG, J.; VIGNEAULT, P.; LI, B. New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. **Remote Sensing of Environment**, v.114, p.1987–1997, 2010.

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

CILIA, C.; PANIGADA, C.; ROSSINI, M.; MERONI, M.; BUSETTO, L.; AMADUCCI, S.; COLOMBO, R. Nitrogen status assessment for variable rate fertilization in maize through hyperspectral imagery. **Remote Sensing**, v. 6, n. 7, p. 6549-6565, 2014.

CLEVERS, J. G.P.W.; GITELSON, A. A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and-3. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 344-351, 2013.

CONPANHIA NACIONAL DE ABASTECIMENTO**. Acompanhamento da safra brasileira de grãos**, v. 2 - Safra 2014/15, n. 9 - Nono levantamento, Brasília, p. 1-104, junho 2015.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; DE COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.

DIKER, K.; BAUSCH, W. C. Potential use of nitrogen reflectance index to estimate plant parameters and yield of maize. **Biosystems Engineering**, v. 85, n. 4, p. 437-447, 2003.

FEILHAUER, H.; ASNER, G. P.; MARTIN, R. E. Multi-method ensemble selection of spectral bands related to leaf biochemistry. **Remote Sensing of Environment**, v. 164, p. 57-65, 2015.

FORNASIERI FILHO, Domingos. **Manual da cultura do milho**. Funep, 2007. 576 p.

FUHRY, M. **A new tikhonov regularization method**. University Honors. 2011. Tese de doutorado.

GITELSON, A A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote sensing of Environment**, v. 80, n. 1, p. 76-87, 2002.

GITELSON, A. A.; PENG, Y.; ARKEBAUER, T. J.; SCHEPERS, J. Relationships between gross primary production, green LAI, and canopy chlorophyll content in maize: Implications for remote sensing of primary production. **Remote Sensing of Environment**, v. 144, p. 65-72, 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**, v. 86, n. 4, p. 542-553, 2003.

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.

HOUBORG, R.; ANDERSON, M.; DAUGHTRY, C.; Utility of an image-based canopy reflectance modeling tool for remote estimation of LAI and leaf chlorophyll content at the field scale. **Remote Sensing of Environment**, v.113, p.259–274, 2009.

HUEMMRICH, K. F. Simulations of seasonal and latitudinal variations in leaf inclination angle distribution: Implications for remote sensing. **Advances in Remote Sensing,** v.2, p.93-101, 2013.

HUNT, E. R.; DORAISWAMY, P. C.; MCMURTREY, J. E.; DAUGHTRY, C. S.; PERRY, E. M.; AKHMEDOV, B. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 103-112, 2013.

LI, F.; MIAO, Y.; FENG, G.; YUAN, F.; YUE, S.; GAO, X.; CHEN, X. Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. **Field Crops Research**, v. 157, p. 111-123, 2014.

LIU, L., SONG, B., ZHANG, S., & LIU, X. A Novel Principal Component Analysis Method for the Reconstruction of Leaf Reflectance Spectra and Retrieval of Leaf Biochemical Contents. **Remote Sensing**, v. 9, n. 11, p. 1113, 2017.

LORENZZETI, J. A. **Princípios físicos de sensoriamento remoto.** São Paulo: Blucher, 2015.

MINOLTA, C. **Manual for chlorophyll meter SPAD-502**. Osaka: Minolta Radiometric Instruments Divisions, 1989.

MIRZAIE, M.; DARVISHZADEH, R.; SHAKIBA, A.; MATKAN, A. A.; ATZBERGER, C.; SKIDMORE, A. Comparative analysis of different uni-and multi-variate methods for estimation of vegetation water content using hyper-spectral measurements. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 1-11, 2014.

MUNNÉ-BOSCH, S.; ALEGRE, L. Die and let live: leaf senescence contributes to plant survival under drought stress. **Functional Plant Biology**, v.31, n.3, p.203-216, 2004.

NAGHETTINI, M.; PINTO, E. J. A. **Correlação e regressão. Hidrologia e Estatística**. Serviço Geológico do Brasil–CPRM, Belo Horizonte, MG, Brasil, 2007.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 4ª ed. São Paulo: Blucher, 2010.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA ALIMENTAÇÃO E AGRICULTURA. Statistics Division. Disponível em: <http://faostat3.fao.org/>. Acesso em: 27 fev. 2018.

PEÑUELAS, J.; GAMON, J. A.; FREDEEN, A. L.; MERINO, J.; FIELD, C. B. Reflectance indices associated with physiological changes in nitrogen-and water-limited sunflower leaves. **Remote Sensing of Environment**, v.48, n.2, p.135-146, 1994.

PONZONI, F.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2007.

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

RITCHIE, Steven W.; HANWAY, John J.; BENSON, Garren O. Como a planta de milho se desenvolve. **Informações agronômicas**, v. 103, p. 1-19, 2003.

RYU, C.; SUGURI, M.; UMEDA, M. Multivariate analysis of nitrogen content for rice at the heading stage using reflectance of airborne hyperspectral remote sensing. **Field Crops Research**, v. 122, n. 3, p. 214-224, 2011.

SHAVER, T. M.; KHOSLA, R.; WESTFALL, D. G. Evaluation of two crop canopy sensors for nitrogen variability determination in irrigated maize. **Precision Agriculture**, v. 12, n. 6, p. 892-904, 2011.

SUN, J., YANG, J., SHI, S., CHEN, B., DU, L., GONG, W., & SONG, S. Estimating Rice Leaf Nitrogen Concentration: Influence of Regression Algorithms Based on Passive and Active Leaf Reflectance. **Remote Sensing**, v. 9, n. 9, p. 951, 2017.

TOBIAS, Randall D. *et al.* An introduction to partial least squares regression**.** In: **Proceedings of the twentieth annual SAS users group international conference**. SAS Institute Inc. Cary, NC, 1995. p. 1250-1257.

VON PINHO, R. G.; BORGES, I. D.; PEREIRA, J. L. D. A. R.; DOS REIS, M. C. Marcha de absorção de macronutrientes e acúmulo de matéria seca em milho. **Revista Brasileira de Milho e Sorgo**, v. 8, n. 02, 2010.

XIA, T.; MIAO, Y.; WU, D.; SHAO, H.; KHOSLA, R.; MI, G. Active Optical Sensing of Spring Maize for In-Season Diagnosis of Nitrogen Status Based on Nitrogen Nutrition Index. **Remote Sensing**, v. 8, n. 7, p. 605, 2016.

YANG, H.; YANG, J.; LV, Y.; HE, J. SPAD Values and Nitrogen Nutrition Index for the Evaluation of Rice Nitrogen Status. **Plant Prod. Sci**., v.17, p.81-92, 2014.

YANG, J.; DU, L.; SUN, J.; ZHANG, Z.; CHEN, B.; SHI, S.; SONG, S. Estimating the leaf nitrogen content of paddy rice by using the combined reflectance and laser-induced fluorescence spectra. **Optics express**, v. 24, n. 17, p. 19354-19365, 2016.

# 3 FUNÇÃO DE RESPOSTA DO MILHO À ÁGUA E NITROGÊNIO EM CONDIÇÕES FERTIRRIGADAS

## RESUMO

Objetivou-se nesse trabalho avaliar os componentes de produção e as eficiências do uso da água (EUA) e do nitrogênio (EUN) na cultura do milho (*Zea mays* L.). O delineamento experimental adotado foi o de blocos aleatorizados em esquema de parcelas subdivididas e quatro repetições. Os tratamentos de irrigação aplicados nas parcelas foram compostos de quatro níveis: 80, 90, 100 e 110% do requerimento hídrico, baseadas na capacidade de campo do solo, e os níveis de N, distribuídos nas subparcelas nos níveis: 0, 60, 120 e 180 kg ha$^{-1}$. As lâminas de irrigação e doses de N influenciaram na altura de plantas e no índice de área foliar. A máxima produtividade foi alcançada na lâmina correspondente a 505 mm e dose de 180 kg ha$^{-1}$ de N, com rendimento de 17819,5 kg ha$^{-1}$. A maior EUA foi obtida em regimes de irrigação reduzida para 80 e 90 % do requerimento hídrico, enquanto que, a maior EUN (67,5 kg kg$^{-1}$) foi atingido com a lâmina 555,7 mm e dose 113,3 kg ha$^{-1}$ de N.

**Palavras-chave:** Manejo da irrigação. Adubação nitrogenada. *Zea mays* L.

## ABSTRACT

The objective of this work was to evaluate the production components and the water use (EUA) and nitrogen (EUN) efficiencies in maize *(Zea mays* L.). The experimental design was randomized blocks in a subdivided plots scheme and four replications. The irrigation treatments applied in the plots were composed of four levels: 80, 90, 100 and 110% of the water requirement, based on the soil field capacity, and the N levels, distributed in the subplots at levels 0, 60, 120 and 180 kg ha$^{-1}$. The water depths and N levels influenced on plant height and leaf area index. The maximum productivity was reached in the irrigation depth corresponding to 505 mm and dose of 180 kg ha$^{-1}$ of N, yielding 17819.5 kg ha$^{-1}$. The highest EUA was obtained in irrigation schemes reduced to 80 and 90% of the water requirement, while the highest EUN (67,5 kg kg$^{-1}$) was reached with the water depth 555,7 mm and dose 113,3 kg ha$^{-1}$ of N.

**Keywords**: Irrigation management. Nitrogen fertilization. *Zea mays* L

## Introdução

O milho (*Zea mays* L.) é uma das culturas mais exploradas em todo o mundo, assumindo papel importante no cenário internacional da produção de alimentos. Segundo a Organização das Nações Unidas para Alimentação e Agricultura - FAO (2015) é um dos principais cultivos irrigados e responsáveis pela utilização de insumos agrícolas. Atualmente grande parte das pesquisas está direcionada a eficiência do uso de recursos visando o aumento da produtividade e ao mesmo tempo diminuir os impactos ambientais gerados pela atividade agrícola (MUELLER *et al.*, 2012).

Na maioria dos sistemas agrícolas o rendimento da cultura é limitado principalmente por fatores como baixa disponibilidade de nutrientes e água, pois comprometem processos fisiológicos relacionados com o crescimento das plantas (GONZALEZ-DUGO *et al.*, 2010). O principal nutriente requerido pela cultura do milho é o nitrogênio (N), por estar altamente relacionado com decréscimo da produção vegetal e com componentes rendimento (LENKA *et al.*, 2013; TEIXEIRA *et al.*, 2014). Essa grande demanda de fertilizantes inorgânicos a base de N, frequentemente, resulta em altas taxas de aplicação no processo produtivo, necessitando assim de um manejo racional que considere os impactos econômicos e ambientais dessas práticas.

Além disso, o sucesso da produção agrícola está associado à gestão dos recursos hídricos. A limitação da quantidade de água para irrigação tem exigido o máximo de técnicas que resultem na eficiência do uso desse recurso e menor impacto na produtividade (DI PAOLO e RINALDI, 2008; KRESOVIC *et al.*, 2016). Segundo Quemada e Gabriel (2016), há uma forte correlação entre as eficiências de uso de água e nitrogênio em muitos sistemas agrícolas. Isso implica que o aprimoramento no gerenciamento desses fatores de produção, simultaneamente, pode proporcionar vantagens no rendimento de água e N separadamente.

Dessa forma, a questão do balanço entre entradas de água e fertilizante no processo produtivo apresenta grande relevância. Segundo Jia *et al.* (2014) a quantidade de N exigido deve ser ajustada às necessidades de irrigação a fim de se obter uma otimização de produção e diminuir as perdas e o efeito residual de nitrato no solo. À vista disso, a melhoria da eficiência do uso de água e nitrogênio são características desejáveis e desempenham papel vital no aumento e otimização da produção agrícola (CAO *et al.*, 2007).

Nesse contexto, este estudo tem como objetivo avaliar os indicadores de produção, a eficiência na utilização de água e do N na cultura do milho, em função de diferentes níveis de irrigação e adubação nitrogenada em condições de campo.

## Material e métodos

O estudo foi conduzido em uma área experimental no Laboratório de Hidráulica e Irrigação do Departamento de Engenharia Agrícola da Universidade Federal do Ceará, Campus do Pici, localizada no município de Fortaleza, CE, coordenadas 3º45' S e 38º 33' W, e altitude de 19 m. Segundo a classificação de Köppen, a área do experimento está localizada em uma região de clima Aw'. O solo da área é classificado como argissolo vermelho-amarelo de textura franco-argilo-arenosa. As plantas de milho (*Zea mays* L.) híbrido AG 1051, foram cultivadas no período de setembro a dezembro de 2015 (ciclo I) e de novembro de 2016 a janeiro de 2017 (ciclo II).

Nas Figuras 2 e 3 encontram-se os croquis do delineamento experimental e esquema da unidade experimental.

Figura 2 - Croqui da área experimental

Fonte: elaboração do autor.

Figura 3 - Esquema da unidade experimental

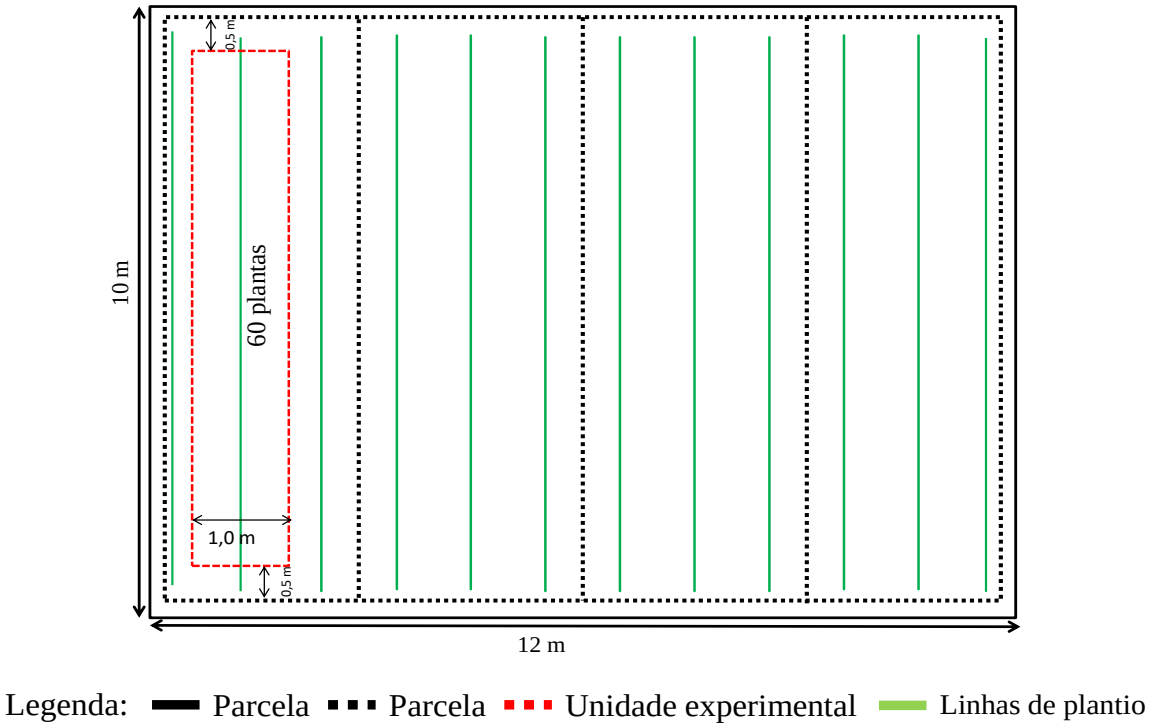


Fonte: elaboração do autor.

O delineamento adotado foi o de blocos aleatorizados, em esquema de parcelas subdivididas replicado quatro vezes, com a parcela principal composta de quatro lâminas de irrigação L110 = 110%, L100 = 100%, L90 = 90% e L80 = 80% do requerimento hídrico, baseados na umidade de capacidade de campo (CC) e a subparcela com quatro doses de adubação nitrogenada (N0 = 0 kg, N60 = 60 kg N120 = 120 kg e N180 = 180 kg de N por hectare) considerando a dose de 120 kg $ha^{-1}$ a quantidade necessária segundo análise de solo.

A descrição detalhada dos tratamentos hídricos encontra-se na Tabela 2.

Tabela 2 - Descrição dos tratamentos de lâminas

| Tratamento | Porcentagem da capacidade de campo (%) | Umidade volumétrica do solo utilizada como setpoint ($cm^3$ $cm^{-3}$) | Lâmina total de água aplicada + precipitação pluviométrica ($m^3$ $ha^{-1}$) | |
|---|---|---|---|---|
| | | | Ciclo I | Ciclo II |
| L110 (L4) | 110 | 24,41 | 5557 | 5060 |
| L100 (L3) | 100 | 21,90 | 4853 | 4335 |
| L90 (L2) | 90 | 19,71 | 3958 | 3928 |
| L80 (L1) | 80 | 17,52 | 3596 | 3693 |

Fonte: elaboração do autor.

A lâmina total de água foi considerada como sendo o somatório das lâminas de irrigação com as precipitações pluviométricas ocorridas durante o experimento. As precipitações encontram-se na Figura 4.

Figura 4 - Dados pluviométricos ocorridos nos ciclos de cultivos: A) ciclo I e B) ciclo II

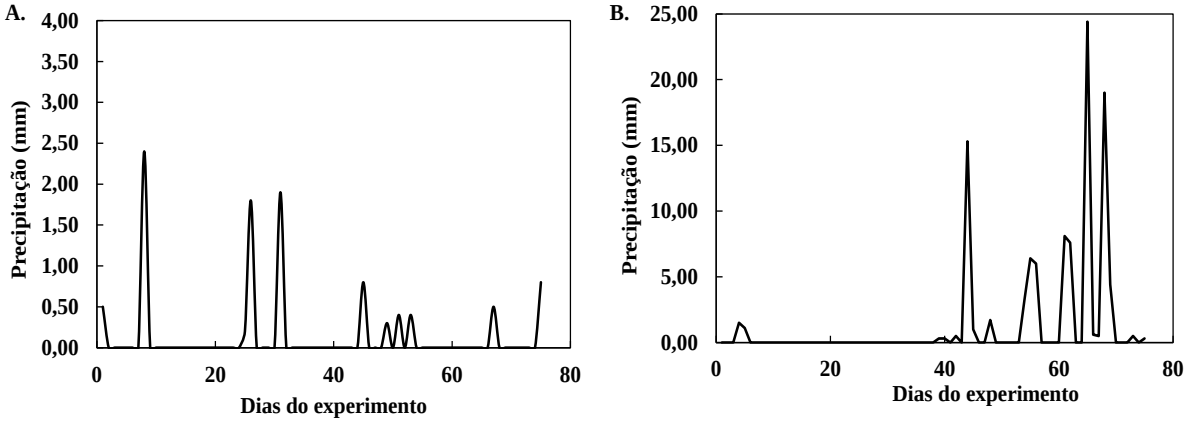


Fonte: Funceme.

A fonte de N utilizado foi a Ureia CO(NH2)2. A adubação foi complementada em todos os tratamentos com 60 kg ha$^{-1}$ de $P_2O_5$, 70 kg ha$^{-1}$ $K_2O$ e 30 kg ha$^{-1}$ de FTE BR 12. O fósforo e micronutrientes foram aplicados todo no plantio, o K foi aplicado 60% no plantio, 40% em cobertura, aos 14 e 35 dias após o plantio (DAP). O N foi aplicado por meio de fertirrigação via gotejamento e parcelado de acordo com a Tabela 3.

Tabela 3 - Parcelamento da adubação de nitrogênio

| | Tratamentos | | | |
|---|---|---|---|---|
| Época | N1 | N2 | N3 | N4 |
| | kg N ha$^{-1}$ | | | |
| Plantio | 0 | 30 | 30 | 30 |
| 14 dias | 0 | 15 | 15 | 25 |
| 21 dias | 0 | 15 | 15 | 25 |
| 28 dias | 0 | 0 | 15 | 25 |
| 35 dias | 0 | 0 | 15 | 25 |
| 42 dias | 0 | 0 | 15 | 25 |
| 49 dias | 0 | 0 | 15 | 25 |
| Total | 0 | 60 | 120 | 180 |

Fonte: elaboração do autor.

A irrigação foi realizada por sistema de gotejamento e manejada por meio de sensores capacitivos de umidade. O tempo de irrigação foi calculado diariamente para cada tratamento hídrico, conforme a lâmina necessária de acordo com a Equação 8.

$$Ti=\frac{(\Theta_t-\Theta_a).\ z.\ EA}{I_a.\ K_r} \tag{8}$$

em que:

$T_i$ - tempo de irrigação, h;
$\Theta_t$ - umidade do solo desejada, $cm^3.cm^3$;
$\Theta_a$ - umidade do solo atual, $cm^3.cm^3$;
z - profundidade do sistema radicular, cm;
EA - Eficiência de aplicação;
$I_a$ - intensidade de aplicação, $mm.h^{-1}$;
$K_r$ – coeficiente de redução.

Foram avaliadas as variáveis de Índice de Área Foliar (IAF), Altura de plantas (AP), Produtividade de Espigas (PE), Eficiência de Uso de Água (EUA) e a Eficiência do Uso de Nitrogênio (EUN). Para determinação do IAF, foram coletadas folhas de três plantas por unidade experimental, utilizando o equipamento LI – 3100 (Li - Cor. Inc. Lincoln, Nebraska, USA). A AP foi aferida com o auxílio de régua graduada. Para a avaliação de produtividade de espigas (PE) foram colhidas 20 plantas por unidade experimental. Foram determinadas o peso total de espigas sem palha e expressos em kg $ha^{-1}$.Todas as variáveis foram coletadas aos 75 dias após o plantio.

A eficiência de uso de água (EUA) foi calculada utilizando os dados de produtividade da cultura e o volume total de água aplicado durante o ciclo, de acordo com a Equação 9.

$$EUA = \frac{Y}{I} \tag{9}$$

em que:
Y - Produtividade, $kg.ha^{-1}$;

I - Lâmina de água aplicada, $m^3.ha^{-1}$.

A eficiência agronômica do uso de nitrogênio (EUN) foi obtida utilizando-se a Equação 10.

$$EUN = \frac{Y_N - Y_0}{N_T} \quad (10)$$

em que:

$Y_N$ - Produtividade de espigas com fertilizante nitrogenado, $kg.ha^{-1}$;

$Y_0$ - Produtividade de espigas sem fertilizante nitrogenado, $kg.ha^{-1}$;

$N_T$ – Quantidade de N aplicado, $kg.ha^{-1}$.

Foi realizada a análise de variância aplicando-se o teste F e, em seguia os efeitos significativos, foram submetidos à análise de regressão. As equações que melhor se ajustaram aos dados foram eleitas com base no teste t, significância dos coeficientes de regressão a ($p<0,05$) e o coeficiente de determinação ajustado ($R^2$ajus).

**Resultados**

Nas Tabelas 4 e 5 encontram-se as médias e os desvios padrão das variáveis analisadas para todos os tratamentos, nos ciclos I e II, respectivamente.

Verificou-se que a altura de plantas (ALT), índice de área foliar (IAF), produtividade de espigas (PE) e a eficiência de uso de nitrogênio (EUN) foram influenciadas significativamente pelos fatores isolados (lâmina e adubação), assim como pela sua interação. Para a variável de eficiência de uso da água (EUA) foi observado apenas o efeito isolado dos fatores (TABELAS 6 e 7).

Tabela 4 - Médias e desvio padrão para as variáveis de Altura de plantas (ALT), Índice de área foliar (IAF), Produtividade de espigas (PE), eficiência do uso da água (EUA) e eficiência do uso de nitrogênio (EUN) para os tratamentos no ciclo I

| Tratam. | ALT (m) | IAF ($m^2$ $m^{-2}$) | PE (kg $ha^{-1}$) | EUA (kg $m^3$ $ha^{-1}$) | EUN ($kg^1$ $kg^{-1}$) |
|---|---|---|---|---|---|
| L1N1 | 1,35 ± 0,14 | 1,56 ± 0,39 | 6212,50 ± 453,25 | 1,72 ± 0,12 | 0,00 ± 0,00 |
| L1N2 | 1,51 ± 0,03 | 1,84 ± 0,24 | 7725,00 ± 693,02 | 2,14 ±0,19 | 34,30 ± 11,55 |
| L1N3 | 1,53 ± 0,07 | 2,17 ± 0,29 | 10937,50 ±1351,63 | 3,04 ± 0,37 | 43,92 ± 11,26 |
| L1N4 | 1,56 ± 0,02 | 2,19 ± 0,37 | 12308,33 ± 1354,38 | 3,42 ± 0,37 | 36,89 ± 7,25 |
| L2N1 | 1,33 ± 0,16 | 1,94 ± 0,43 | 8004,16 ± 793,18 | 2,02 ± 0,20 | 0,00 ± 0,00 |
| L2N2 | 1,55 ± 0,30 | 2,19 ± 0,54 | 10100,00 ± 903,69 | 2,55 ± 0,22 | 54,72 ± 15,06 |
| L2N3 | 1,51 ± 0,17 | 2,32 ± 0,07 | 12238,33 ± 648,23 | 3,09 ± 0,16 | 45,18 ± 5,40 |
| L2N4 | 1,64 ± 0,08 | 2,32 ± 0,56 | 13100,00 ± 1539,84 | 3,30 ± 0,38 | 34,90 ± 8,55 |
| L3N1 | 1,43 ± 0,09 | 1,80 ± 0,14 | 8829,16 ± 625,11 | 1,81 ± 0,13 | 0,00 ± 0,00 |
| L3N2 | 1,81 ± 0,11 | 2,25 ± 0,48 | 11420,83 ± 1157,93 | 2,35 ± 0,23 | 55,62 ± 19,29 |
| L3N3 | 1,96 ± 0,07 | 2,40 ± 0,19 | 15733,33 ± 695,48 | 3,24 ± 0,14 | 63,75 ± 5,79 |
| L3N4 | 1,97 ± 0,05 | 2,65 ± 0,34 | 17054,16 ± 1349,37 | 3,51 ± 0,27 | 49,83 ± 7,49 |
| L4N1 | 1,59 ± 0,12 | 2,33 ± 0,26 | 9058,33 ± 407,99 | 1,63 ± 0,07 | 0,00 ± 0,00 |
| L4N2 | 1,90 ± 0,11 | 2,85 ± 0,35 | 12300,00 ± 972,58 | 2,21 ± 0,17 | 61,38 ± 16,21 |
| L4N3 | 1,98 ± 0,11 | 2,90 ± 0,44 | 16629,16 ± 1302,87 | 2,99 ± 0,23 | 66,77 ± 10,85 |
| L4N4 | 2,09 ± 0,18 | 3,15 ± 0,49 | 16362,50 ± 417,83 | 2,94 ± 0,07 | 43,03 ± 2,31 |

Fonte: elaboração do autor.

Tabela 5 - Médias e desvio padrão para as variáveis de Altura de plantas (ALT), Índice de área foliar (IAF), Produtividade de espigas (PE), eficiência do uso da água (EUA) e eficiência do uso de nitrogênio (EUN) para os tratamentos no ciclo II

| Tratam. | ALT (m) | IAF ($m^2$ $m^{-2}$) | PE (kg $ha^{-1}$) | EUA (kg $m^3$ $ha^{-1}$) | EUN ($kg^1$ $kg^{-1}$) |
|---|---|---|---|---|---|
| L1N1 | 1,75 ± 0,04 | 2,43 ± 0,28 | 11179,16 ± 584,48 | 2,20 ± 0,11 | 0,00 ± 0,00 |
| L1N2 | 1,79 ± 0,03 | 2,77 ± 0,34 | 15462,50 ± 542,69 | 3,05 ± 0,10 | 82,15 ± 9,04 |
| L1N3 | 1,96 ± 0,09 | 3,42 ± 0,25 | 17200,00 ± 946,72 | 3,39 ± 0,18 | 55,55 ± 7,88 |
| L1N4 | 1,98 ± 0,02 | 3,65 ± 0,09 | 18179,16 ± 230,28 | 3,59 ± 0,05 | 42,47 ± 1,27 |
| L2N1 | 1,75 ± 0,04 | 2,28 ± 0,08 | 11520,83 ± 1570,87 | 2,65 ± 0,36 | 0,00 ± 0,00 |
| L2N2 | 1,81 ± 0,02 | 2,64 ± 0,07 | 13833,33 ± 1026,68 | 3,19 ± 0,23 | 58,05 ± 10,14 |
| L2N3 | 1,95 ± 0,03 | 3,07 ± 0,09 | 16220,83 ± 2370,70 | 3,74 ± 0,54 | 51,00 ± 19,75 |
| L2N4 | 1,97 ± 0,02 | 3,59 ± 0,06 | 17562,50 ± 258,33 | 4,05 ± 0,06 | 41,45 ± 1,43 |
| L3N1 | 1,69 ± 0,02 | 2,25 ± 0,07 | 12154,16 ± 273,31 | 3,09 ± 0,07 | 0,00 ± 0,00 |
| L3N2 | 1,73 ± 0,03 | 2,44 ± 0,09 | 13520,83 ± 1403,06 | 3,44 ± 0,35 | 26,45 ± 23,38 |
| L3N3 | 1,78 ± 0,05 | 2,62 ± 0,07 | 14120,83 ± 1130,99 | 3,59 ± 0,28 | 18,22 ± 9,42 |
| L3N4 | 1,88 ± 0,05 | 3,14 ± 0,13 | 16591,66 ± 1050,61 | 4,22 ± 0,26 | 25,88 ± 5,87 |
| L4N1 | 1,70 ± 0,08 | 1,95 ± 0,19 | 12575,00 ± 2596,88 | 3,40 ± 0,70 | 0,00 ± 0,00 |
| L4N2 | 1,71 ± 0,05 | 2,20 ± 0,18 | 13925,00 ± 1846,54 | 3,77 ± 0,50 | 51,52 ± 30,77 |
| L4N3 | 1,76 ± 0,02 | 2,82 ± 0,21 | 14308,33 ± 1476,76 | 3,87 ± 0,40 | 28,95 ± 12,30 |
| L4N4 | 1,85 ± 0,03 | 3,35 ± 0,10 | 15612,50 ± 755,02 | 4,22 ± 0,24 | 26,55 ± 4,19 |

Fonte: elaboração do autor.

Tabela 6 - Resumo da análise de variância para as variáveis de altura de plantas (ALT), índice de área foliar (IAF), produtividade de espigas (PE), eficiência de uso da água (EUA) e de nitrogênio (EUN) para o ciclo I

| F. V | G. L | Teste F | | | | |
|---|---|---|---|---|---|---|
| | | ALT | IAF | PE | EUA | EUN |
| Bloco | 3 | 4,65* | 2,97 n.s | 3,11 n.s | 2,51 n.s | 2,15 n.s |
| Lâmina – a | 3 | 36,66** | 11,01** | 61,47** | 4,20* | 7,69** |
| Resíduo – a | 9 | | | | | |
| Adubação - b | 3 | 31,26** | 12,21** | 204,64** | 201,05** | 123,4** |
| a x b | 9 | 2,19* | 0,26* | 3,49** | 1,89 n.s | 2,30 * |
| Resíduo - b | 36 | | | | | |
| Total | 63 | | | | | |
| CV a (%) | | 8,31 | 19,61 | 8,85 | 10,47 | 26,70 |
| CV b (%) | | 7,03 | 15,79 | 7,40 | 7,46 | 24,67 |

F.V – Fonte de variação; G.L – graus de liberdade; (a) – Lâmina; (b) – Adubação; CV – coeficiente de variação; **, *, n.s – significativo pelo teste f a 1%, 5% e não significativo, respectivamente. Fonte: elaboração do autor.

Tabela 7 - Resumo da análise de variância para as variáveis de altura de plantas (ALT), índice de área foliar (IAF), produtividade de espigas (PE), eficiência de uso da água (EUA) e de nitrogênio (EUN) para o ciclo II

| F. V | G. L | Teste F | | | | |
|---|---|---|---|---|---|---|
| | | ALT | IAF | PE | EUA | EUN |
| Bloco | 3 | 2,38 n.s | 6,17 n.s | 2,49 n.s | 2,35 n.s | 5,05 * |
| Lâmina – a | 3 | 50,34** | 46,59** | 3,16 n.s | 10,93** | 26,24** |
| Resíduo – a | 9 | | | | | |
| Adubação - b | 3 | 87,45** | 284,40** | 57,45** | 48,013** | 58,90** |
| a x b | 9 | 3,01** | 4,91** | 2,90* | 1,53 n.s | 3,20** |
| Resíduo - b | 36 | | | | | |
| Total | 63 | | | | | |
| CV a (%) | | 1,93 | 4,86 | 10,31 | 11,10 | 29,61 |
| CV b (%) | | 2,21 | 4,51 | 7,38 | 8,29 | 37,63 |

F.V – Fonte de variação; G.L – graus de liberdade; (a) – Lâmina; (b) – Adubação; CV – coeficiente de variação; **, *, n.s – significativo pelo teste f a 1%, 5% e não significativo, respectivamente. Fonte: elaboração do autor.

A partir de análise quantitativa da função de resposta à ação interativa dos fatores lâmina de irrigação e doses de nitrogênio para as variáveis de altura de plantas (ALT) e índice de área folia (IAF), obteve-se a função mais significativa representada pela regressão linear ($p < 0,01$) mostrada nas Figuras 5 e 6.

Figura 5 - Altura de plantas (ALT) de milho submetidas a diferentes níveis de lâminas de irrigação em função da adubação nitrogenada, nos ciclos I (A) e II (B)

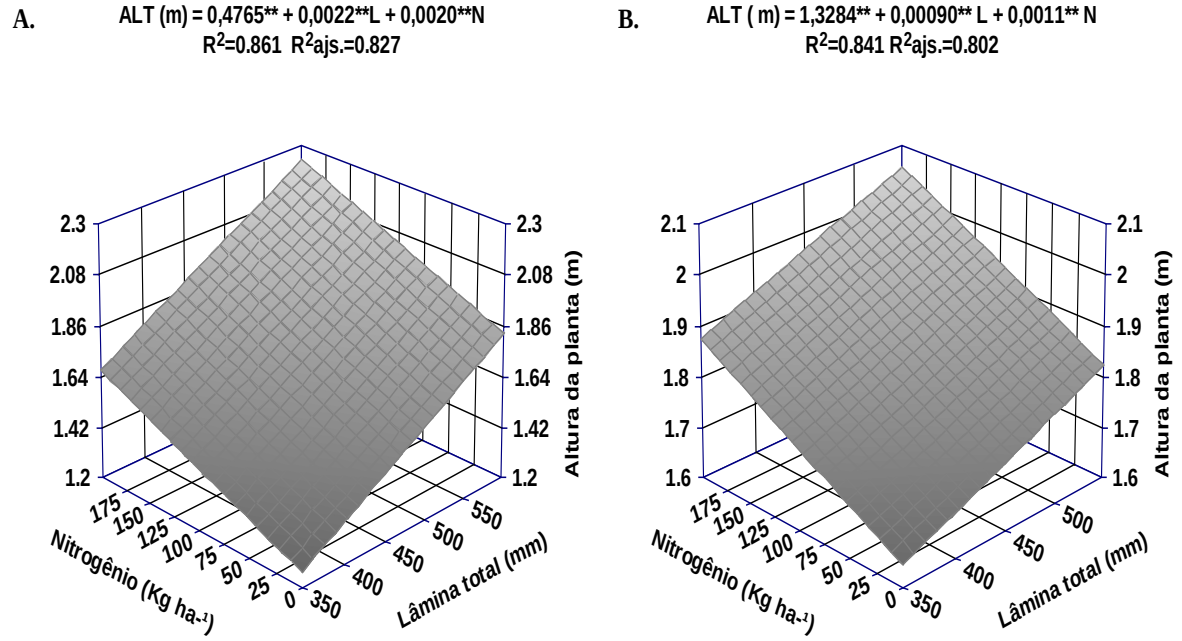


Fonte: elaboração do autor.

Figura 6 - Índice de Área Foliar (IAF) em plantas de milho submetidas a diferentes níveis de lâminas de irrigação em função da adubação nitrogenada, nos ciclos I (A) e II (B)

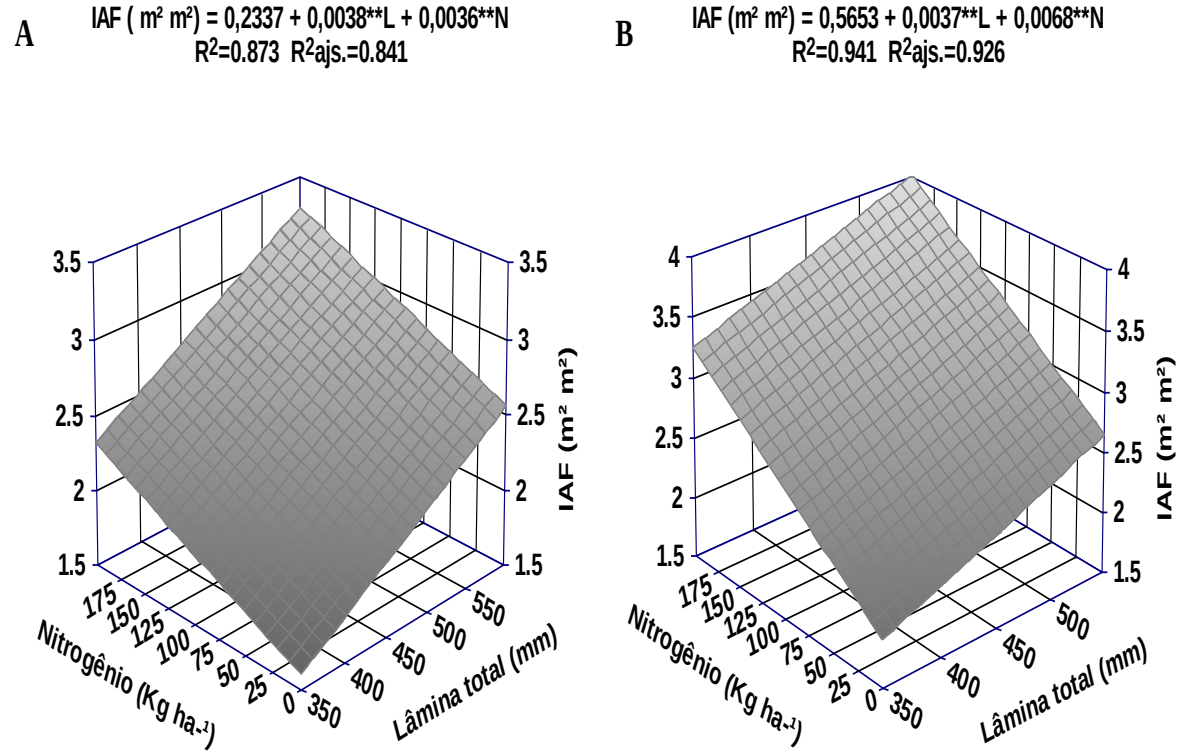


Fonte: elaboração do autor.

As variáveis de ALT e IAF aumentaram linearmente em função das doses crescentes de N e lâmina de irrigação com coeficientes de determinação ajustado variando entre 0,802 e 0,926.

Esses resultados sugerem presença de efeito simultâneo no crescimento vegetativo das plantas. Para ALT considerando os dois ciclos, os maiores valores de altura (2,09 m) foram obtidos com a combinação da lâmina total de 555, 7 mm e dose de nitrogênio 180 kg ha$^{-1}$ (FIGURA 5-A). O IAF máxima de 3,70 m² m² foi obtido utilizando a lâmina de 506 mm e a dosagem de nitrogênio de 180 kg ha$^{-1}$ (FIGURA 6-B).

Figura 7 - Produtividade de espigas sem palha (PE) em plantas de milho submetidas a diferentes níveis de lâminas de irrigação em função da adubação nitrogenada, nos ciclos I (A) e II (B)

**A.** PE (Kg ha-¹) = -29742,533* + 146,654*L - 0,1362*L² + 58,456*N - 0,1068
$R^2$=0.948 $R^2$ajs.=0.922

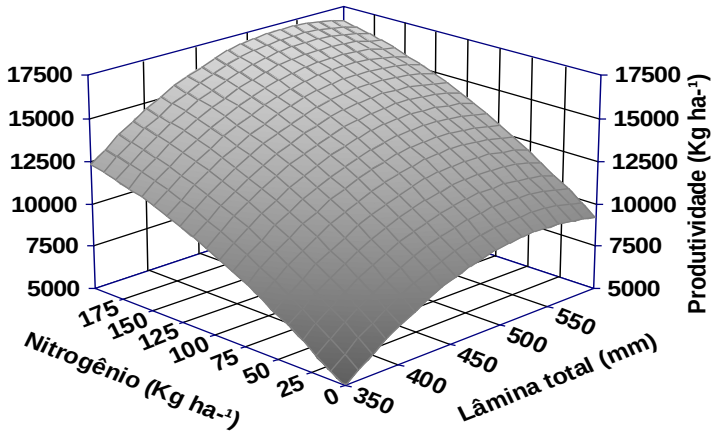


**B.** PE (Kg ha-¹) = 8598,773 + 4,730L + 0,0071L + 37,826*N - 0,0558N
$R^2$=0.871 $R^2$ajs.=0.806

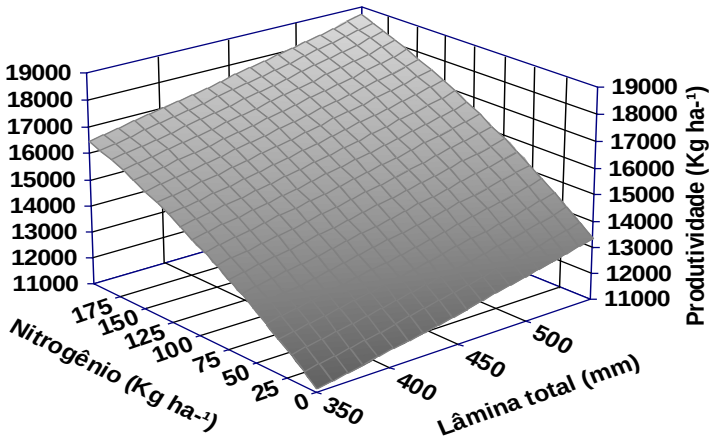


Fonte: elaboração do autor.

Quanto a produtividade de espigas (PE), as equações de regressão e as funções de superfície de resposta indicam efeito polinomial quadrático com efeito significativo para interação dos fatores ($p < 0,01$) (FIGURA 7).

A produtividade máxima estimada para o ciclo I (16778,3 kg $ha^{-1}$) foi obtida com a combinação da lâmina 538,12 mm e dosagem de N de 180 kg $ha^{-1}$ (FIGURA 7-A). No ciclo II foram observadas melhores produtividades, com o maior rendimento de 17819,5 kg $ha^{-1}$ quando irrigados com lâmina de 506 mm e aplicados 180 kg $ha^{-1}$ (FIGURA 7-B).

Figura 8 - Eficiência do uso de Nitrogênio (EUN) em plantas de milho submetidas a diferentes níveis de lâminas de irrigação em função da adubação nitrogenada, nos ciclos I (A) e II (B)

A. $EUN\ (Kg\ Kg^{-1}) = -31,3139^{*} + 0,0721^{*}L + 1,0270^{**}N - 0,0045^{**}N^2$
$R^2=0,921\quad R^2ajs.=0,893$

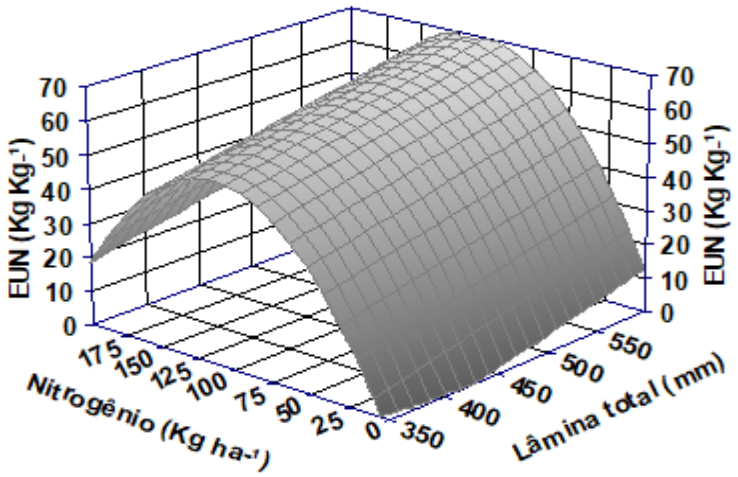


B. $EUN\ (Kg\ Kg^{-1}) = -69,3066 + 0,1726^{*}L + 0,8796^{**}N - 0,0040^{**}N^2$
$R^2=0,686\quad R^2ajs.=0,572$

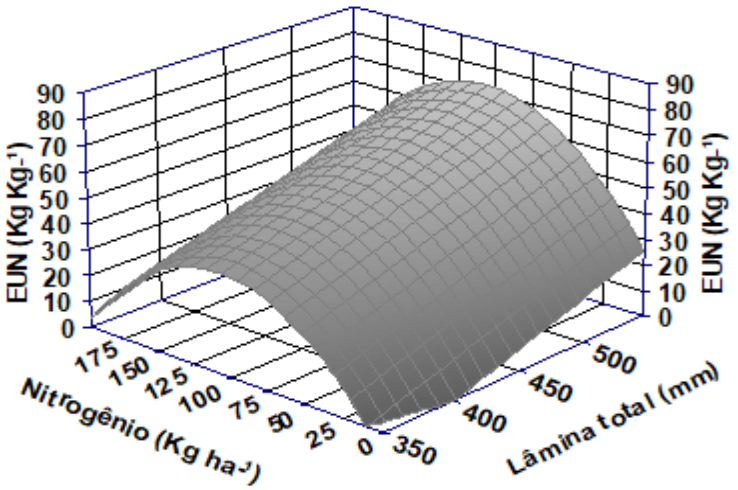


Fonte: elaboração do autor.

As superfícies de resposta para a Eficiência do Uso de Nitrogênio (EUN) para os dois ciclos de cultivo são mostrados na Figura 8.

O melhor ajuste foi obtido pelo modelo polinomial quadrático ($p < 0,01$). Os valores de EUN apresentaram variação entre os ciclos produtivos. No ciclo I, a melhor eficiência no uso de N (67,5 kg $kg^{-1}$) foi obtida como a lâmina 555,7 mm e dose 113,3 kg $ha^{-1}$. No ciclo II a o ponto de máxima (65,3 kg $kg^{-1}$) foi atingido com a combinação de 506 mm e 107,5 kg $ha^{-1}$.

Figura 9 - Eficiência do uso de água (EUA) em função das lâminas de irrigação e doses de nitrogênio para o ciclo I (A e B) e II (C e D)

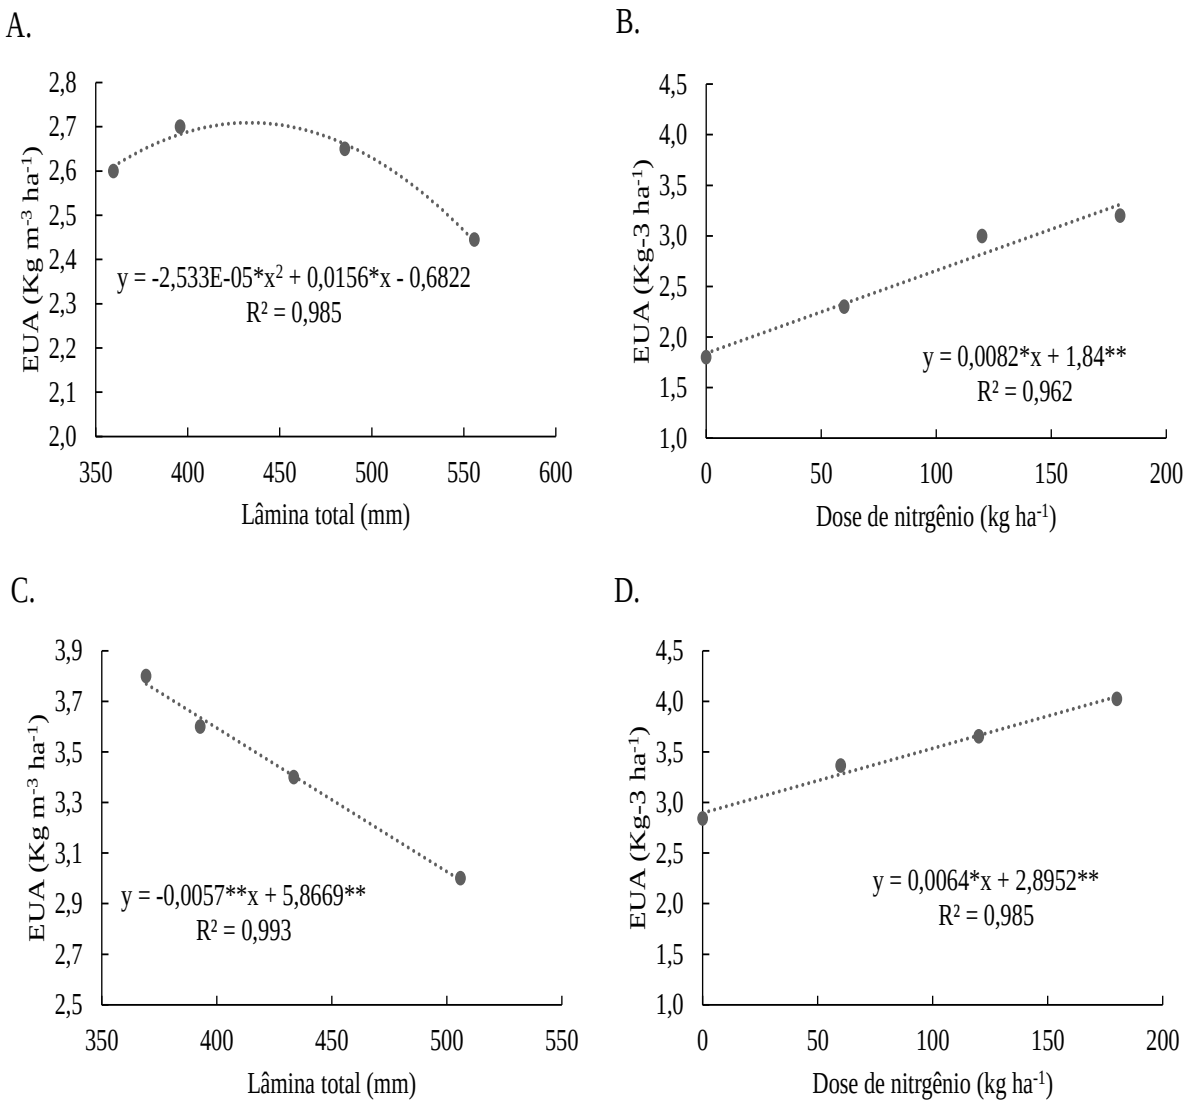


Fonte: elaboração do autor.

O resultado da análise de regressão para a variável de eficiência do uso de água (EUA) para os fatores isolados encontra-se na Figura 9. Com relação à EUA em função das lâminas para o ciclo I, verificou-se tendência quadrática ($p<0,05$), com valores máximos encontrados no tratamento L90 (FIGURA 9-A.), enquanto que para o ciclo II, o ajuste foi linear ($p<0,05$) com decremento da EUA em função do aumento da lâmina de irrigação (FIGURAS 9-C).

Quanto à EUA em função dos níveis de nitrogênio, o efeito observado foi linear ($p<0,05$) para ambos os ciclos, com incremento da EUN em função do aumento das doses de nitrogênio (FIGURAS 9-B e 9-D)

**Discussão**

As disponibilidades de N e de água podem afetar a expansão foliar simultaneamente. Segundo Taiz e Zeiger (2013) os déficits hídrico e nutricional são responsáveis por mecanismos de desidratação das células e crescimento vegetativo, respectivamente. Na cultura do milho esses dois fatores condicionam fortemente as variações de altura da planta e área foliar (CAKIR, 2004; FRANÇA *et al.*, 2011).

A redução da ALT em função das lâminas e doses foi evidenciada, com valores em média mais altos no ciclo I com decréscimo de 22,0 % e 21,0% nos tratamentos (N0) e (L80) em comparação com o suprimento ideal (N100) e (L100), respectivamente. Para o IAF as maiores reduções em função da dose de N foram observadas no ciclo II, com diminuição de 34,9 % no tratamento N0 em relação ao N100. Para efeito de lâmina de irrigação, a redução foi de 17,3% entre L80 e L100. Esses resultados estão de acordo com Teixeira *et al.* (2014) que constataram o efeito do estresse hídrico e nutricional na redução do IAF em milho irrigado, atribuindo tais resultados, sobretudo, às variações na capacidade de alocar recursos, principalmente na eficiência do uso da radiação e da água. Segundo Wang *et al.* (2017), o aumento da disponibilidade hídrica no solo aumenta a absorção de N, contribuído para o aumento linear da biomassa no milho.

Levando em consideração a interação lâmina *vs* adubação, constatou-se efeito aditivo dos fatores em termos de produtividade. Porém, é possível observar uma tendência de decrescimento expressiva a partir dos tratamentos com irrigação e dosagem de N em excesso (L110 e N180). Esses resultados estão de acordo com encontrados por Gholamhoseini *et al.*,

(2013) para o milho, em que encontram a tendência de diminuição do rendimento nas doses excessivas de N em sistemas de irrigação com alta frequência de irrigação e Irmak *et al.* (2016), que constataram a tendência quadrática da produtividade de grãos em função de níveis variados de fornecimento da irrigação.

Os resultados encontrados sugerem que a disponibilidade hídrica amplifica os ganhos em produtividade por meio do melhor aproveitamento do N. Os efeitos de interação entre estado hídrico e nutricional na produtividade de plantas é discutido na literatura como um "trade-off" importante referente a questão de ganho de rendimento na produção vegetal. Segundo Di Paolo e Rinaldi (2008), a influência da disponibilidade de N no rendimento da cultura do milho tende a ser menor sob restrição hídrica. Neste estudo as limitações hídricas foram moderadas com redução máxima de 20% da capacidade de campo, mas foram suficientes para redução em produtividade, mesmo nas dosagens recomendadas. Esses resultados indicam que em níveis adequados de água no solo, as plantas melhoraram a absorção simultânea de água e N, aumentando a eficiência de uso desses recursos. Gholamhoseini *et al.* (2013) relatam uma maior resposta de N no rendimento do milho em condições favoráveis de água no solo, com aumento de 63% em comparação com regime hídrico reduzido em condições semiáridas. Segundo os autores, a queda no rendimento está ligada a diminuição do crescimento da planta causado pela queda na absorção de N. A redução da produtividade em baixos níveis de água no solo está ligada a queda na produção e translocação de fotoassimilados e, consequentemente, absorção pelos grãos (AYDINSAKIR *et al.*, 2013).

Com relação a EUN, os resultados indicam que o suprimento adequado de água melhorou a eficiência na utilização de N pela planta. Esses resultados indicam que, principalmente, a aplicação em excesso de N tende a diminuir a eficiência na utilização pelas plantas. Tal fato está diretamente ligado às perdas por aplicação e por limitação de absorção desse nutriente pelas plantas. Segundo Valero *et al.* (2005), a EUN tende a decrescer com o aumento das taxas de fertilizantes. Fernandes *et al.* (2005), em estudo com seis cultivares de milho com diferentes doses de N, obtiveram maiores valores de EUN quando se utilizou a dose de 30 kg $ha^{-1}$ de N, tendendo a diminuir quando aumentado as doses de N para 90 e 180 kg $ha^{-1}$. No nosso estudo, diferentemente, verificou-se o maior valor na dose recomendada (N120=120 kg $ha^{-1}$), em relação a dose deficitária (N60= 60 kg $ha^{-1}$). Tais resultados podem estar ligados a diminuição de perdas potenciais pelo maior parcelamento das aplicações, e consequentemente, melhor capacidade de absorção, além das altas produções alcançadas nas

doses N120 e N180 em relação a N60. Segundo Binde *et al.* (2000), o parcelamento promove o maior aproveitamento de N pela sincronização entre as aplicações e os períodos de alta demanda, refletindo na produção. Assim as tendências quadráticas da EUN em função dos níveis de lâmina de irrigação podem diferir de outros estudos encontrados na literatura. Por exemplo, Pandney *et al.* (2000), em estudo com a cultura do milho, constataram tendência linear crescente da EUN em relação a lâmina de irrigação. Nesse caso, a maior oferta de água no solo favoreceu a melhor utilização do nitrogênio pelas plantas por meio do aumento da absorção de nitrogênio em condições de total suprimento hídrico, em relação a redução de 57% na irrigação. Nessa situação, a absorção de nitrogênio foi mais dependente do N aplicado do que o suprimento de água, embora a absorção de N tenha diminuído com maiores déficits de água e N. No entanto, Chilundo *et al.* (2016) verificaram maiores valores de EUN em condições de menor disponibilidade hídrica em tratamentos com 25% de redução em sistema de gotejamento, nesse caso as perdas de nitrogênio foram associadas às maiores lâminas de irrigação, que foram além da capacidade de armazenamento. Segundo Djaman *et al*. (2013), essa condição favorece a perda residual de NO3-, por lixiviação ou desnitrificação, deve-se a sua alta mobilidade no solo em condições de alta umidade, causando redução na eficiência do uso de N para produção.

Salienta-se que em nosso experimento, as reduções variaram ao máximo de 20% do requerimento hídrico, baseados no monitoramento via solo, ao invés do cálculo da necessidade hídrica levando em consideração o clima. Segundo Zotarelli *et al.* (2011), a utilização de sensores de umidade do solo visando atender a real demanda de água para planta, tende a melhorar a EUN, pelo maior controle na quantidade de água aplicada e consequente manutenção do N próximo a zona radicular da cultura, proporcionando menores perdas por lixiviação de NO3- . Além disso, o fornecimento mais aproximado da demanda real da cultura somado a fertilização adequada por meio da fertirrigação, por exemplo, tendem a aumentar a EUN nas culturas (QUEMADA; GABRIEL, 2016).

A tendência de decrescimento da EUA em função do aumento da disponibilidade hídrica observadas está de acordo com estudos encontrados na literatura, a exemplo de Aydinsakir *et al.* (2013), que encontraram melhores EUA no milho em tratamentos com 50% da demanda da cultura em relação aos níveis 75% e 100% de irrigação. Em estudo semelhante, Irmak *et al.* (2016), mostraram a tendência decrescente da EUA em função da diminuição da irrigação no milho, e relatam que a aplicação além da necessidade hídrica da

cultura pode ter contribuído mais para produção de biomassa em vez de aumentar rendimento de grãos, diminuído potencialmente a EUA.

A tendência a diminuir a EUA nas lâminas maiores mostra a importância da manutenção de teores adequados de água para cultura melhorando a absorção da água disponível no solo. Zotarelli *et al.* (2010), compararam combinações de três níveis de N e três tratamentos de aplicação de água via gotejamento em pimentão (*Capsicum annuum* L.), e verificaram a redução de 62% da quantidade de água ideal aplicada no tratamento baseado na manutenção em tempo real da umidade do solo, em comparação ao método convencional via clima, sem comprometer o rendimento comercial.

Para o efeito isolado da adubação, verificou-se acréscimo linear da EUA com a aplicação de doses crescentes de nitrogênio ($p<0,05$) (FIGURAS 9-C e 9-D.). Esses resultados sugerem que plantas bem nutridas melhoram a capacidade de absorção de água e utilização na produção de fotoassimilados, corroborando com Teixeira *et al.* (2014), que demostraram que a eficiência do uso de água aumenta em torno de 20% em plantas de milho totalmente fertilizadas, independente da condição hídrica submetida. Em estudo sobre a interação da fertilização de N e irrigação na produtividade do milho, Gheysari *et al.* (2015), verificaram a diminuição da EUN com a diminuição dos níveis de disponibilidade de água, indicando que o maior fornecimento de N aumenta a tolerância em termos de rendimento quando submetidos a estresse hídrico.

Tanto a EUA como EUN, tendem a diminuir além da capacidade de campo e dose recomendada, respectivamente, sugerindo que um equilíbrio entre o fornecimento de N e água deve ser considerado. Neste estudo o maior rendimento foi observado no tratamento L100 (506 mm) e N180 (180 kg $ha^{-1}$) no ciclo II (17819,5 kg $ha^{-1}$), mostrando que em termos de produtividade, o conteúdo de água adequado foi determinante, porém a dosagem a mais do recomendado (N180) foi a que obteve maior produção.

O aumento da produtividade conforme a maior disponibilidade de nitrogênio e água, mesmo além da dose recomendada na cultura do milho é documentada por Jia *et al.* (2014), porém como relatado anteriormente, o excesso de irrigação e aplicação de N maior que a capacidade de absorção da cultura, intensifica o efeito residual de nitrato no solo. Dessa forma, as taxas de aplicação de fertilizantes acompanhadas da manutenção da água no solo em níveis adequados são a chave para o aumento da produtividade e diminuição dos impactos ambientais.

**Conclusões**

O manejo da irrigação baseado na manutenção da água no solo em níveis adequados para cultura é uma alternativa para melhorar a eficiência do uso dos de recursos, proporcionando ganhos em produtividade e reduzindo potenciais riscos ambientais. Os resultados obtidos permitiram concluir que as lâminas de irrigação e doses de nitrogênio influenciam a altura de plantas, índice de área foliar e produtividade de espigas. Quanto à produtividade de espigas, o rendimento máximo é alcançado com aplicação da lâmina correspondente a 506 mm e dose de 180 kg $ha^{-1}$ de N, com rendimento de 17819,5 kg $ha^{-1}$. A maior eficiência de uso da água é obtida em regimes de irrigação reduzida solo para 80 e 90% do requerimento hídrico, enquanto que, a maior eficiência do uso de nitrogênio (67,5 kg $kg^{-1}$) é atingido com a lâmina 555,7 mm e dose 113,3 kg $ha^{-1}$ de N.

# REFERÊNCIAS

AYDINSAKIR, K.; ERDAL, S.; BUYUKTAS, D.; BASTUG, R.; TOKER, R. The influence of regular deficit irrigation applications on water use, yield, and quality components of two corn (*Zea mays* L.) genotypes. **Agricultural water management**, v. 128, p. 65-71, 2013.

BINDER, D. L.; SANDER, D. H.; WALTERS, D. T. Maize response to time of nitrogen application as affected by level of nitrogen deficiency. **Agronomy Journal**, v. 92, n. 6, p. 1228-1236, 2000.

CAKIR, R. Effect of water stress at different development stages on vegetative and reproductive growth of corn. **Field Crops Research**, v. 89, n. 1, p. 1-16, 2004.

CAO, H. X.; ZHANG, Z. B.; XU, P.; CHU, L. Y.; SHAO, H. B.; LU, Z. H.; LIU, J. H. Mutual physiological genetic mechanism of plant high water use efficiency and nutrition use efficiency. Colloids and Surfaces B: **Biointerfaces**, v. 57, n. 1, p. 1-7, 2007.

CHILUNDO, M.; JOEL, A.; WESSTRÖM, I.; BRITO, R.; MESSING, I. Effects of reduced irrigation dose and slow release fertiliser on nitrogen use efficiency and crop yield in a semi-arid loamy sand. **Agricultural Water Management**, v. 168, p. 68-77, 2016.

DI PAOLO, E.; RINALDI, M. Yield response of corn to irrigation and nitrogen fertilization in a Mediterranean environment. **Field Crops Research**, v. 105, n. 3, p. 202-210, 2008.

DJAMAN, K.; IRMAK, S.; MARTIN, D. L.; FERGUSON, R. B.; BERNARDS, M. L. Plant nutrient uptake and soil nutrient dynamics under full and limited irrigation and rainfed maize production. **Agronomy Journal**, v. 105, n. 2, p. 527-538, 2013.

FAO - FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. Statistics Division. 2015. Disponível em: < http://faostat3.fao.org/>. Acesso em: 18 Abr. 2016.

FERNANDES, F. C. S.; BUZETTI, S.; ARF, O.; ANDRADE, J. D. C. Doses, eficiência e uso de nitrogênio por seis cultivares de milho. **Revista Brasileira de Milho e Sorgo**, v. 4, n. 2, p. 195-204, 2005.

FRANÇA, S.; MIELNICZUK, J.; ROSA, L. M. G.; BERGAMASCHI, H.; BERGONCI, J. I. Nitrogênio disponível ao milho: Crescimento, absorção e rendimento de grãos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande. Vol. 15, n. 11 (nov. 2011), p. 1143-1151, 2011.

GHEYSARI, M.; LOESCHER, H. W.; SADEGHI, S. H.; MIRLATIFI, S. M.; ZAREIAN, M. J.; HOOGENBOOM, G. Water-yield relations and water use efficiency of maize under nitrogen fertigation for semiarid environments: experiment and synthesis. In: **Advances in Agronomy**. Academic Press, 2015. p. 175-229.

GHOLAMHOSEINI, M.; AGHAALIKHANI, M.; SANAVY, S. M.; MIRLATIFI, S. M. Interactions of irrigation, weed and nitrogen on corn yield, nitrogen use efficiency and nitrate leaching. **Agricultural water management**, v. 126, p. 9-18, 2013.

GONZALEZ-DUGO, V.; DURAND, J.; GASTAL, F. Water deficit and nitrogen nutrition of crops. A review. **Agronomy for sustainable development**, v. 30, n. 3, p. 529-544, 2010.

IRMAK, S.; DJAMAN, K.; RUDNICK, D. R. Effect of full and limited irrigation amount and frequency on subsurface drip-irrigated maize evapotranspiration, yield, water use efficiency and yield response factors. **Irrigation science**, v. 34, n. 4, p. 271-286, 2016.

JIA, X.; SHAO, L.; LIU, P.; ZHAO, B.; GU, L.; DONG, S.; ZHAO, B. Effect of different nitrogen and irrigation treatments on yield and nitrate leaching of summer maize (*Zea mays* L.) under lysimeter conditions. **Agricultural Water Management**, v. 137, p. 92-103, 2014.

KRESOVIĆ, B.; TAPANAROVA, A.; TOMIĆ, Z.; ŽIVOTIĆ, L.; VUJOVIĆ, D.; SREDOJEVIĆ, Z.; GAJIĆ, B. Grain yield and water use efficiency of maize as influenced by different irrigation regimes through sprinkler irrigation under temperate climate. **Agricultural Water Management**, v. 169, p. 34-43, 2016.

LENKA, S.; SINGH, A. K.; LENKA, N. K. Soil water and nitrogen interaction effect on residual soil nitrate and crop nitrogen recovery under maize–wheat cropping system in the semi-arid region of northern India. **Agriculture, ecosystems & environment**, v. 179, p. 108-115, 2013.

MUELLER, N. D.; GERBER, J. S.; JOHNSTON, M.; RAY, D. K.; RAMANKUTTY, N.; FOLEY, J. A. Closing yield gaps through nutrient and water management. **Nature**, v. 490, n. 7419, p. 254-257, 2012.

PANDEY, R. K.; MARANVILLE, J. W.; & CHETIMA, M. M. Deficit irrigation and nitrogen effects on maize in a Sahelian environment: II. Shoot growth, nitrogen uptake and water extraction. **Agricultural Water Management**, v. 46, n. 1, p. 15-27, 2000.

QUEMADA, M.; GABRIEL, J. L. Approaches for increasing nitrogen and water use efficiency simultaneously. **Global Food Security**, v. 9, p. 29-35, 2016.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. 5. ed. Porto Alegre: Artmed, 2013. 918p.

TEIXEIRA, E. I., GEORGE, M., HERREMAN, T., BROWN, H., FLETCHER, A., CHAKWIZIRA, E.; NOBLE, A. The impact of water and nitrogen limitation on maize biomass and resource-use efficiencies for radiation, water and nitrogen. **Field Crops Research**, v. 168, p. 109-118, 2014.

VALERO, J. D. J.; MATURANO, M.; RAMÍREZ, A. A.; MARTÍN-BENITO, J. T.; ÁLVAREZ, J. O. Growth and nitrogen use efficiency of irrigated maize in a semiarid region as affected by nitrogen fertilization. **Spanish Journal of Agricultural Research**, v. 3, n. 1, p. 134-144, 2005.

WANG, Y.; JANZ, B.; ENGEDAL, T.; NEERGAARD, A. Effect of irrigation regimes and nitrogen rates on water use efficiency and nitrogen uptake in maize. **Agricultural water management**, v. 179, p. 271-276, 2017.

ZOTARELLI, L.; DUKES, M. D.; SCHOLBERG, J. M. S.; FEMMINELLA, K.; MUNOZ-CARPENA, R. Irrigation scheduling for green bell peppers using capacitance soil moisture sensors. **Journal of Irrigation and Drainage Engineering**, v. 137, n. 2, p. 73-81, 2011.

# 4 RESPOSTA ESPECTRAL DO MILHO SUBMETIDO A DIFERENTES NÍVEIS DE IRRIGAÇÃO E ADUBAÇÃO NITROGENADA

## RESUMO

O presente trabalho teve como objetivo avaliar e caracterizar as variações de reflectância em espectros de folhas isoladas e de dossel de plantas de milho (*Zea mays* L.) em função de diferentes níveis de irrigação e adubação nitrogenada em condições de laboratório e de campo, respectivamente. Para tanto, um experimento com delineamento em blocos aleatorizados com esquema de parcelas subdivididas e quatro repetições foi adotado. Os tratamentos de irrigação aplicados nas parcelas foram compostos de quatro níveis: 80, 90, 100 e 110% do requerimento hídrico, baseadas na capacidade de campo do solo e os níveis de N, distribuídos nas subparcelas nos níveis: 0, 60, 120 e 180 kg $ha^{-1}$. Foram realizadas leituras espectrais e determinada a concentração de N foliar nos estádios V8, R1 e R3 da cultura nos níveis de campo e de laboratório. As variações de reflectância foram avaliadas através da análise por componentes principais (ACP) e análise derivativa. A aplicação da primeira derivada permitiu ressaltar regiões sensíveis ao N nas faixas entre (470 nm a 550 nm) e (720 nm a 750 nm), enquanto que a segunda derivada evidenciou nas faixas (700 nm e 725 nm). Cerca de 90% e 95,12% do total da variação nos espectros pode ser explicada utilizando três PCs, para dados de laboratório e campo, respectivamente. Os fatores que compõem a explicação das PCs apresentaram diferentes características dependendo da forma de coleta de dados. A PC de maior relevância (PC1), em dados de dossel foi explicada principalmente pelo poder refletor ou a refletividade ao longo de todo espectro. No nível de folha, a PC1 foi influência principalmente pelo início borda vermelha até o SWIR (700 nm a 2500 nm).

**Palavras-chave:** Hiperespectral. *Zea mays* L. PCA. Análise derivativa.

## ABSTRACT

The present study aimed to evaluate and characterize the variations in the reflectance spectra of single leaves and canopy corn plants (*Zea mays* L.) as a function of different levels of irrigation and nitrogen fertilization under laboratory and field conditions, respectively. For this, an experiment with a randomized block design with subdivided plots and four

replications was adopted. The irrigation treatments applied in the plots were composed of four levels: 80, 90, 100 and 110% of the water requirement, based on the soil field capacity, and the N levels, distributed in the subplots at levels 0, 60, 120 and 180 kg $ha^{-1}$. Spectral readings were determined and the concentration of foliar N at the V8, R1 and R3 stages of the culture at the field and laboratory levels was determined. The reflectance variations were evaluated through principal component analysis (PCA) and derivative analysis. The application of the first derivative allowed to highlight N-sensitive regions in the bands between (470 nm to 550 nm) and (720 nm to 750 nm), while the second derivative showed bands (700 nm and 725 nm). About 90% and 95.12% of the total variation in the spectra can be explained using three PCs, for laboratory and field data, respectively. The factors that make up the explanation of the PCs presented different characteristics depending on the form of data collection. The most relevant PC (PC1) in canopy data was mainly due to the reflective power or reflectivity over the entire spectrum. At leaf level, PC1 was mainly influenced by the red border beginning to SWIR (700 nm at 2500 nm).

**Keywords:** Hyperspectral. *Zea mays* L. PCA. Derivative analysis

## Introdução

O sensoriamento remoto tem se mostrado uma técnica oportuna, não destrutiva e de potencial aplicação na agricultura em vários níveis, para estimar, quantificar e monitorar atributos biofísicos e bioquímicos da vegetação (SAHOO *et al.*, 2015; XIA *et al.*, 2016). Os pigmentos fotossintetizantes estão entre os principais agentes bioquímicos estudados, pois as alterações nas quantidades estão diretamente ligadas à condição nutricional das plantas (INOUE *et al.*, 2016). O principal nutriente responsável nesse processo de alteração é o N. A deficiência desse elemento induz mudanças na estrutura e cor nas folhas (clorose), o que possibilita a identificação de alterações em valores de reflectância da vegetação à adubação (CHEN *et al.*, 2010). Nesse sentido, a reflectância da vegetação em função de tratamentos de adubação tem sido utilizada principalmente para analisar regiões especificas do espectro sensível a mudanças no estado nutricional (MIPHOKASAP *et al.*, 2012; INOUE *et al.*, 2016). Essas faixas específicas são de grande interesse para a seleção de bandas espectrais para formulação de modelos e de índices de vegetação relacionados com estado nutricional das plantas (ZHU *et al.*, 2006; YANG *et al.* 2016). Esse tipo de abordagem tem sido amplamente

adotado para aplicações em cultivos de larga escala como o milho (*Zea mays* L.) (SCHLEMMER *et al.,* 2013; QUEMADA *et al.,* 2014).

Entre as faixas de interesse, o espectro do visível (VIS) e do infravermelho próximo (NIR) são as principais regiões onde é possível a identificação das alterações na resposta espectral em função da adubação. No VIS as alterações devem-se principalmente à degradação de pigmentos, especialmente da clorofila, caracterizando a diminuição da intensidade da cor verde (CILIA *et al.,* 2014). Em geral os padrões de reflectância no verde (550 nm) e absorção próximo ao vermelho (670 nm) são amplamente explorados em estudos sobre deficiência de N em plantas (DAUGHTRY *et al.,* 2000; HUNT *et al.,* 2013). A região do infravermelho próximo (NIR) é influenciada pela estrutura celular do mesófilo foliar, onde ocorre elevado espalhamento da radiação eletromagnética incidente (HEEGE *et al.,* 2008). Dessa forma, mudanças estruturas no tecido foliar e aumento de biomassa devido a variações no suprimento nutricional, a exemplo da disponibilidade de N, tem efeito considerável na resposta nessa faixa (SCHLEMMER *et al.,* 2013). Assim, o NIR tem grande potencial na previsão do rendimento das culturas e na diferenciação de tratamentos de adubação (QUEMADA *et al.,* 2014). As alterações espectrais na faixa entre (680-780 nm), posição também denominada de “borda vermelha”, têm sido utilizadas na identificação de estresse por deficiência nutricional (CHO; SKIDMORE, 2006). Particularmente, essa faixa apresenta alta sensibilidade às mudanças na concentração de nitrogênio foliar (CLEVERS; GITELSONB, 2013).

Além da composição bioquímica e morfológica da vegetação outro fator que interfere na reflectância da vegetação é o estádio de desenvolvimento da cultura. Mudanças na cobertura foliar nos diferentes estádios de desenvolvimento da cultura influenciam diretamente na composição do espectro (LI *et al*., 2014). A senescência e a mudança na composição de pigmentos são processos graduais que variam ao longo do ciclo de desenvolvimento da cultura. Geralmente maiores concentrações de clorofila são observadas na fase de crescimento em relação à fase reprodutiva, alterando assim quantidade de radiação absorvida dentro do dossel da planta (GITELSON *et al.,* 2014).

Com relação à dinâmica da reflectância da vegetação em função dos tratamentos de disponibilidade de N, algumas técnicas são utilizadas para análise detalhada do espectro de reflectância. A análise derivativa do espectro tem sido utilizada para identificar regiões sensíveis relacionadas à concentração de N foliar (MIPHOKASAP *et al.,* 2012). Os autores observaram que a aplicação da primeira derivada possibilitou ressaltar a faixa entre 630-750

nm com alta correlação a variações de N em cultivares de cana-de-açúcar. Inoue *et al.* (2016), em estudo sobre as variações do espectro em relação ao conteúdo de clorofila na cultura do arroz, verificaram que a primeira derivada destacou picos de reflectância em torno de 710, 1130 e 1320 nm em função da concentração crescente de pigmentos na folha. De modo semelhante, Corti *et al.* (2017) utilizaram a segunda derivada para detectar a perda de coloração verde ocasionada pela diminuição do conteúdo de clorofila em plantas de espinafre, observável próximo à faixa entre 680 e 715 nm.

Para uma análise detalhada da reflectância da vegetação, a análise de Componentes Principais - PCA é um método estatístico multivariado largamente utilizado (LIU *et al.*, 2017; SUN *et al.*, 2017). Para a análise da reflectância de alvos, a PCA possibilita a redução da dimensionalidade dos dados e a caracterização dos fatores responsáveis pela variabilidade espectral nos conjuntos de dados (MOREIRA; GALVÃO, 2010). Por esse motivo, estudos têm usado a PCA para a análise dos atributos mais importantes e que explicam a variação da reflectância espectral da vegetação e sua relação com variáveis bioquímicas foliares (YANG *et al.*, 2016; LIU *et al.*, 2017). Assim, consegue-se reduzir o número de variáveis sem perda considerável de informações contidas no conjunto de dados originais, permitindo analisar simultaneamente um grande número de bandas espectrais. Além disso, a PCA apresenta a vantagem de contornar o problema da multicolinearidade, que é um fator inerente aos dados hiperespectrais (MIRZAIE *et al.*, 2014).

Diante do exposto, objetivou-se caracterizar e relacionar variações de reflectância em espectros de folhas isoladas e de dossel de plantas de milho em função de diferentes níveis de irrigação e de adubação nitrogenada em condições de campo e de laboratório.

## Material e métodos

### *Área experimental e tratamentos*

O estudo foi conduzido em uma área experimental no Laboratório de Hidráulica e Irrigação do Departamento de Engenharia Agrícola da Universidade Federal do Ceará, Campus do Pici, localizada no município de Fortaleza, CE, coordenadas 3º45' S e 38º 33' W, e altitude de 19 m. Segundo a classificação de Köppen, a área do experimento está localizada

em uma região de clima Aw'. O solo da área é classificado como argissolo vermelho-amarelo de textura franco-argilo-arenosa.

O delineamento adotado foi o de blocos aleatorizados, em esquema de parcelas subdivididas replicado quatro vezes, com a parcela principal composta de quatro níveis de lâminas de irrigação correspondente a L1= 80%, L2 = 90%, L3 = 100% e L4 = 110% do requerimento hídrico, baseados na umidade de capacidade de campo (CC), e a subparcela, com quatro doses de adubação nitrogenada (N0 = 0 kg, N60 = 60 kg N120 = 120 kg e N180 = 180 kg de N por hectare) considerando a dose 120 kg $ha^{-1}$ a quantidade necessária segundo análise de solo. A descrição detalhada dos tratamentos encontra-se na Tabela 8.

Tabela 8 - Descrição dos tratamentos

| Tratamento | Porcentagem da capacidade de campo (%) | Lâmina total de água aplicada ($m^3$ $ha^{-1}$) Ciclo I - 2015 | Lâmina total de água aplicada ($m^3$ $ha^{-1}$) Ciclo II - 2016 | Quantidade de N aplicado (kg $ha^{-1}$) |
|---|---|---|---|---|
| L1N1 | 80 | 3596 | 3693 | 0 |
| L1N2 | 80 | 3596 | 3693 | 60 |
| L1N3 | 80 | 3596 | 3693 | 120 |
| L1N4 | 80 | 3596 | 3693 | 180 |
| L2N1 | 90 | 3958 | 3928 | 0 |
| L2N2 | 90 | 3958 | 3928 | 60 |
| L2N3 | 90 | 3958 | 3928 | 120 |
| L2N4 | 90 | 3958 | 3928 | 180 |
| L3N1 | 100 | 4853 | 4335 | 0 |
| L3N2 | 100 | 4853 | 4335 | 60 |
| L3N3 | 100 | 4853 | 4335 | 120 |
| L3N4 | 100 | 4853 | 4335 | 180 |
| L4N1 | 110 | 5557 | 5060 | 0 |
| L4N2 | 110 | 5557 | 5060 | 60 |
| L4N3 | 110 | 5557 | 5060 | 120 |
| L4N4 | 110 | 5557 | 5060 | 180 |

Fonte: Elaboração do autor.

As plantas de milho (*Zea mays* L.) híbrido AG 1051 foram cultivadas no período de setembro a dezembro de 2015 (ciclo I) e de novembro de 2016 a janeiro de 2017 (ciclo II). A fonte de N utilizado foi a Ureia CO(NH2)2 utilizando fertirrigação. A adubação foi complementada em todos os tratamentos com 60 kg $ha^{-1}$ de $P_2O_5$, 70 kg $ha^{-1}$ K2O e 30 kg $ha^{-1}$ de FTE BR 12. A irrigação foi realizada por sistema de gotejamento e manejada por meio de sensores capacitivos de umidade.

***Coleta de dados espectrais***

A obtenção de dados espectrais foi realizada utilizando o espectrômetro FieldSpec Pro FR 3 (Analytical Spectral Devices Inc.), que opera na região de 350 a 2500 nm, com resolução de 1 nm em laboratório e em campo. Em laboratório, as leituras foram feitas em sala escura sem interferência da luz externa. A distância do sensor ao alvo foi de 5 cm, a distância da fonte luminosa (lâmpada de 250 Watts) ao alvo foi de 70,7 cm, com ângulo zenital de 45° e a distância da superfície do piso a fonte luminosa 50 cm, conforme Figura 10.

Figura 10 - Aquisição de dados espectrais em laboratório

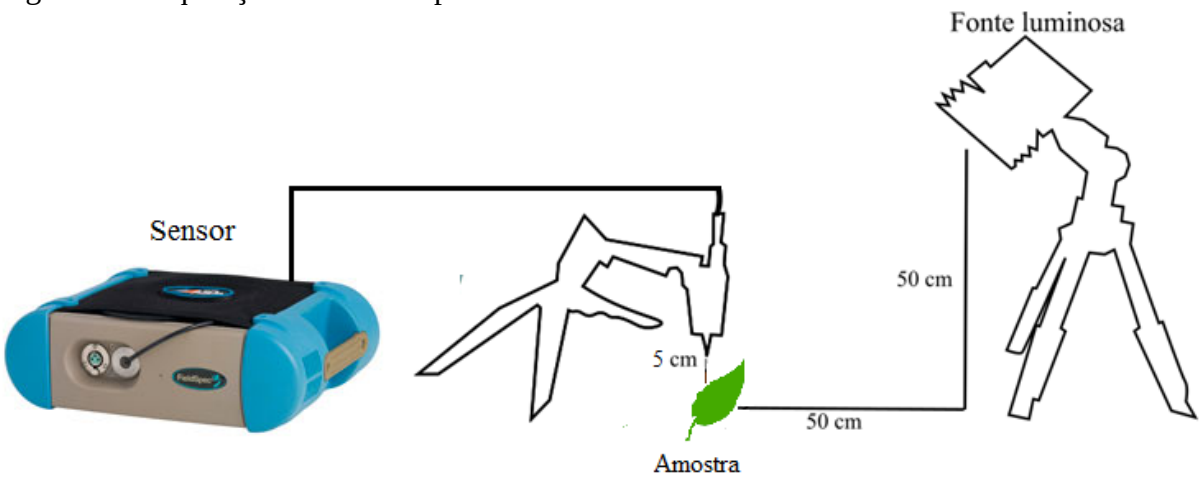


Fonte: Elaboração do autor.

Em campo, as leituras foram realizadas a uma altura de 70 cm do dossel das plantas, procedendo três aferições por planta.

A aquisição de dados ocorreu no período entre as 10:00 hs – 14:00 hs, sempre em dias com ausência de nebulosidade.

***Análise dos dados***

A análise dos dados compreendeu a caracterização gráfica das variações de reflectância espectral em função dos tratamentos de adubação nitrogenada, ao emprego das técnicas de análise derivativa, para exploração de regiões especificas no espectro e a análise de componentes principais, visando extrair as principais fontes de variabilidade e compreender a importância das variáveis nos conjuntos de dados.

A técnica de análise da derivada é comumente usada para ressaltar as feições sensíveis em regiões especificas do espectro advindo da presença de componentes que favorecem a absorção ou o espalhamento da luz e que podem ocasionalmente ser mascarados por outros componentes do alvo (GOODIN *et al.*, 1993; HAN, 2005). A primeira derivada pode ser entendida como a mudança ou a diferença da reflectância em função de um dado comprimento de onda (TSAI; PHILPOT, 1998). A obtenção das derivadas de primeira e de segunda ordem são obtidas numericamente pelo método das diferenças finitas, de acordo com as equações 11 e 12, respectivamente.

$$\frac{dR_\lambda}{dx} \cong \frac{R_{i+1} - R_{i-1}}{\Delta x} \tag{11}$$

$$\frac{d^2 R_\lambda}{dX^2} = \frac{d}{dx}\left(\frac{dR}{dx}\right) \cong \frac{R_{i+1} - 2R_i + R_{i-1}}{(\Delta x)^2} \tag{12}$$

Em que: $dR_\lambda$ é derivada do espectro de reflectância com relação ao comprimento de onda x, $\Delta x$ é a separação entre duas bandas (ou pontos) sucessivas. Sendo $\Delta x = x_j - x_k$ , considerando que $x_j > x_k$ e que o intervalo de bandas seja constante.

A Análise por Componentes Principais (PCA) é uma abordagem interessante para análise da resposta espectral de reflectância da vegetação. A principal função dessa ferramenta é reduzir a dimensionalidade dos dados espectrais e extrair as características mais importantes das variáveis (YANG *et al.*, 2016). A PCA reduz o conjunto de dados originais em variáveis transformadas, ou componentes principais - PC, que são obtidos por uma combinação linear dos dados originais, são ortogonais, baseados na variância total, e apresentam elevado poder de explicação (BRO; SMILDE, 2014). Essa transformação é conduzida de tal forma que o primeiro PC consegue captar a maior variação possível, e cada componente subsequente, por sua vez, possui a maior variação possível sob a restrição de que é ortogonal aos componentes anteriores (LIU *et al.*, 2017).

Na PCA são obtidos os autovalores, também conhecido como raiz latente, que representa a quantia de variância explicada por um fator ou componente e os autovetores, que indicam as variáveis de entradas mais importantes para explicar cada componente. Nesse estudo, a PCA foi aplicada separadamente para os dados obtidos em laboratório e campo nos

dois ciclos e nas diferentes fases fenológicas. Assim os dados foram divididos em dois conjuntos: dados de laboratório (n=256 amostras) e campo (n = 320 amostras) (TABELA 9). Os valores de reflectância de todo o espectro foram usados como variáveis de entrada.

Tabela 9 - Descrição da coleta de dados espectrais

| Dados | n | Descrição da coleta de dados (número de leituras por estádio) | | | | | |
|---|---|---|---|---|---|---|---|
| | | Ciclo I | | | Ciclo II | | |
| | | V8 | R1 | R3 | V8 | R1 | R3 |
| Laboratório | 256 | - | - | 64 | 64 | 64 | 64 |
| Campo | 320 | 64 | 64 | 64 | 64 | - | 64 |

Fonte: Elaboração do autor.

As componentes foram selecionadas a partir da análise do diagrama de sedimentação ou *scree plot* (gráfico de declive) dos autovalores e variância explicada.

Os pesos de carregamento (*loadings*) e os seus respectivos coeficientes das PCs selecionadas foram analisados com o objetivo de verificar a contribuição da reflectância nos diferentes comprimentos de onda para explicar cada componente selecionada. Os *loadings* e seus coeficientes fornecem a composição das PCs em relação às bandas espectrais (variáveis X), permitindo compreender a influência de cada um dos PCs para descrever o espectro.

## Resultados

### *Reflectância espectral e análise derivativa*

Nas Figuras 11 e 12, encontram-se os valores médios, máximos, mínimos e os percentis (25º e 75º) para os dados de reflectância obtidos em laboratório e em campo nos anos de 2015 (ciclo I) e 2016 (ciclo 2).

Figura 11 - Espectros de reflectância coletados em laboratório em todos os estádios fenológicos para: (A) 2015 n=64 e (B) 2016 n=192

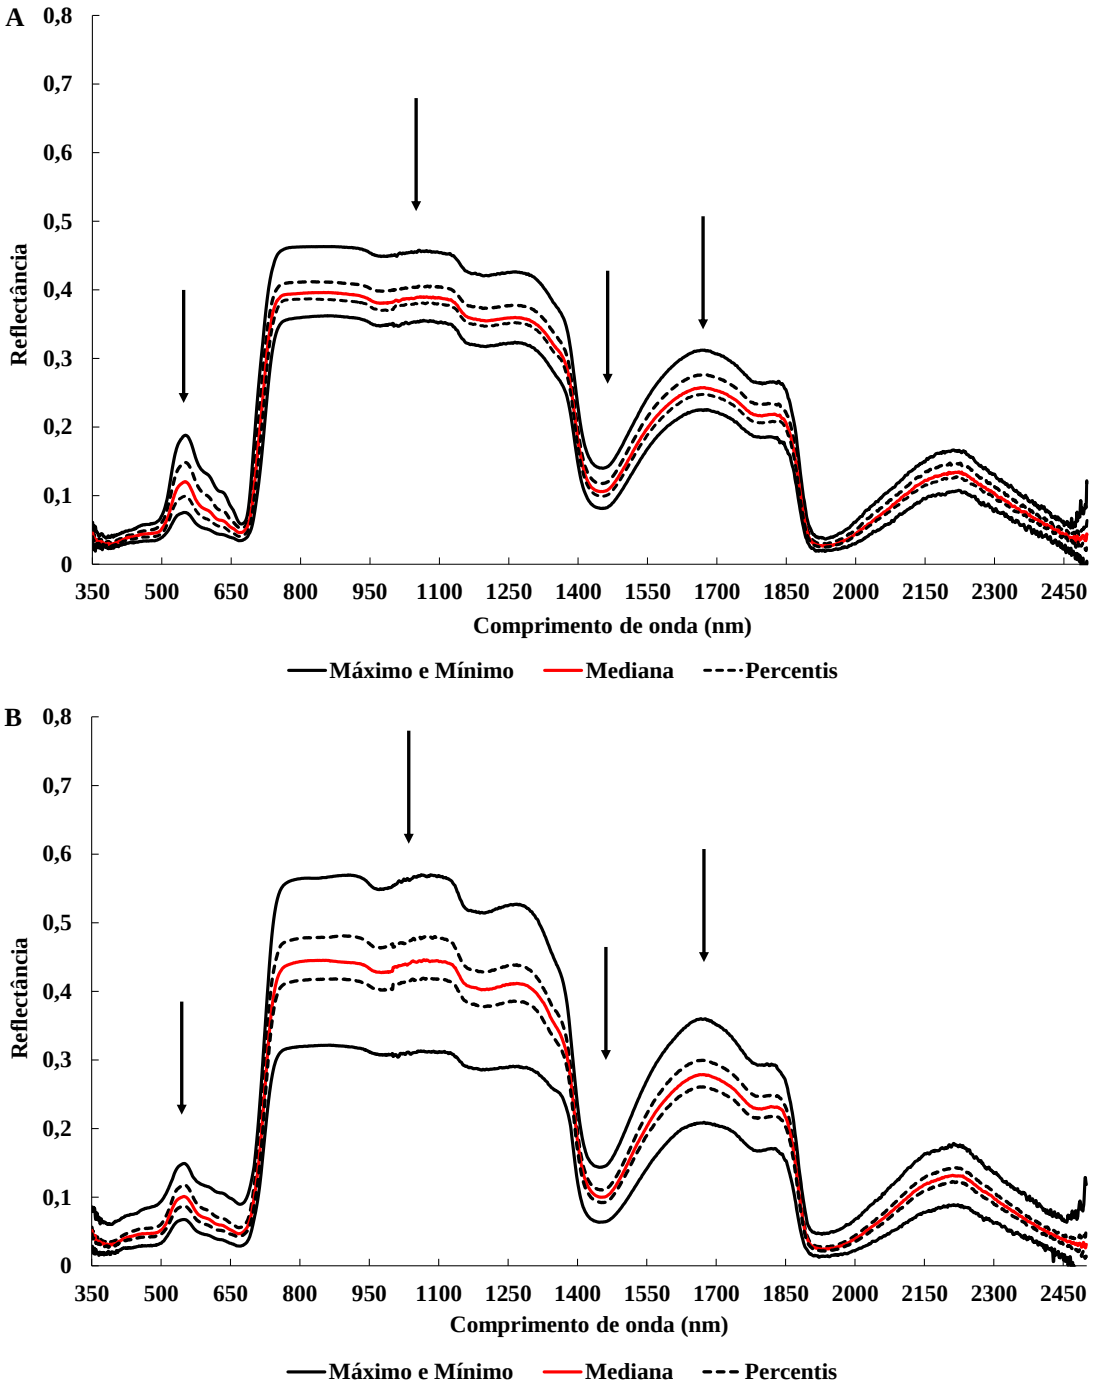


Fonte: elaboração do autor.

Figura 12 - Espectros de reflectância coletados em campo em todos os estádios fenológicos para: (A) 2015 n=192 e (B) 2016 n=128

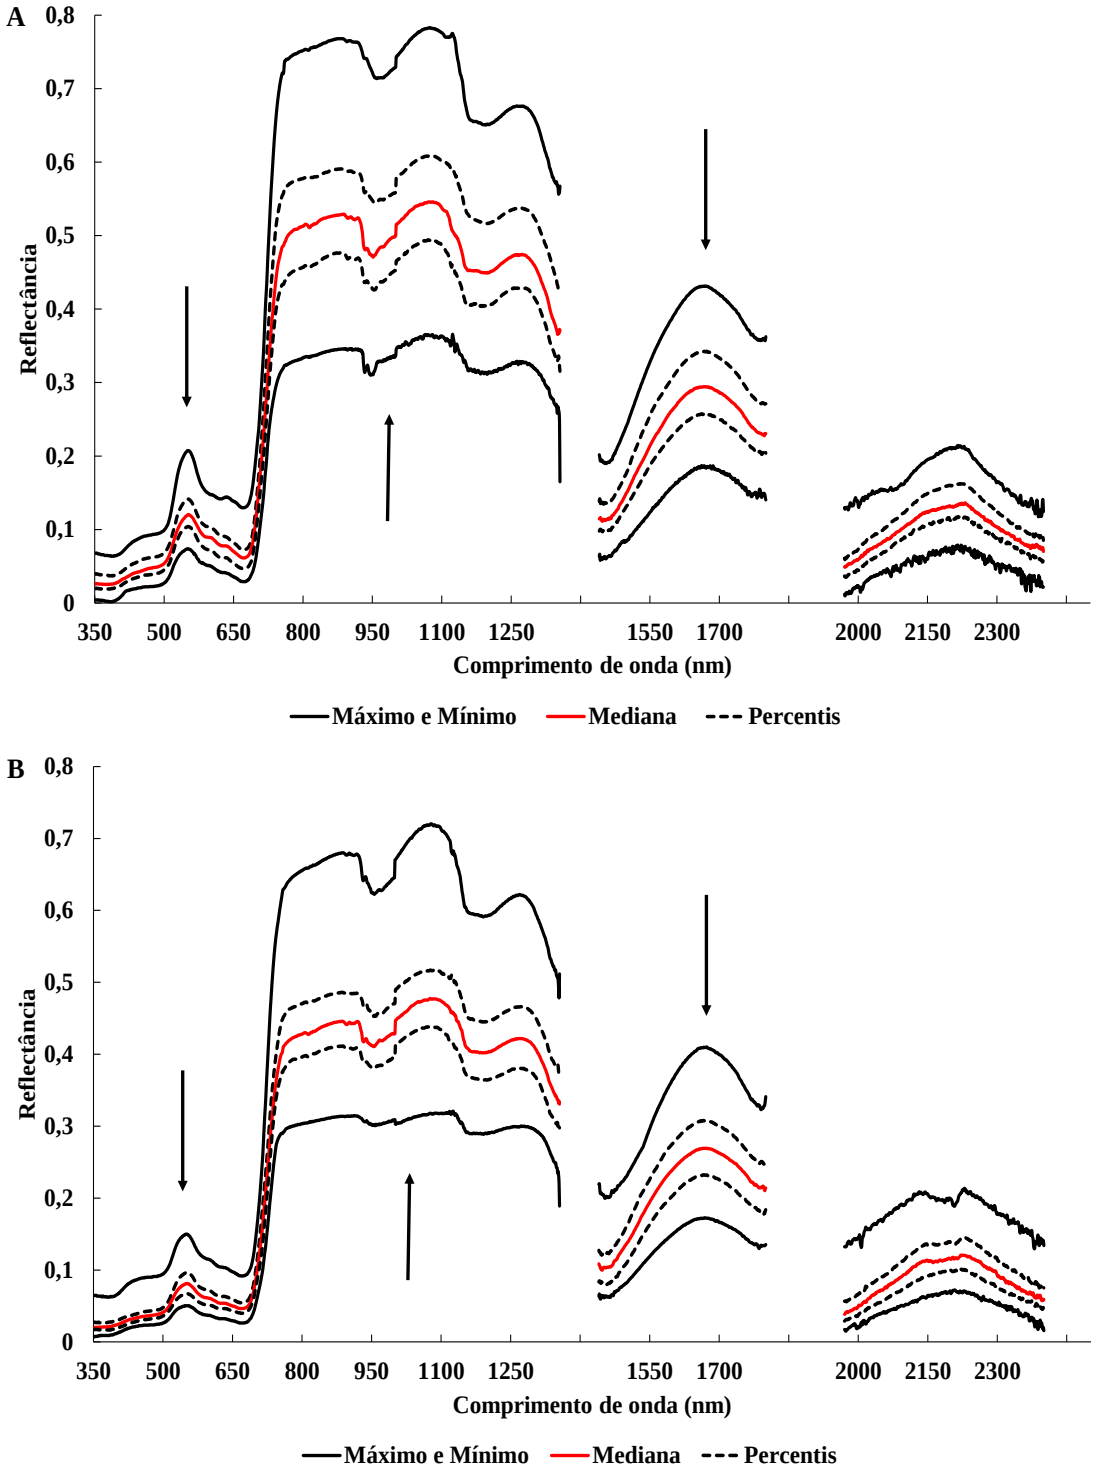


Fonte: elaboração do autor.

Os espectros de reflectância medidos tiveram uma ampla variação nas regiões do espectro relacionados à concentração de clorofila (450-750 nm), estrutura do mesófilo foliar

(800-1300 nm), água (1400 nm) e teor de matéria seca (1600 nm). Os valores de reflectância obtidos em condições de laboratório não excederam 0,6 nas regiões de máximo valor, entre 800 nm e 1300 nm.

Para os dados de campo, observou-se maior variação em todas as regiões de resposta de componentes bioquímicos da folha. Os valores máximos foram encontrados entre 800 nm e 1200 nm, com reflectância entre 0,7 e 0,8.

O fator de reflectância, a primeira e a segunda derivada dos perfis espectrais do milho nos diferentes tratamentos de adubação nitrogenada para dados obtidos em laboratório nos dois ciclos (I e II), são apresentados nas Figuras 13,14,15,16, 17, 18, 19, 20 e 21. A análise derivativa foi aplicada com a finalidade de amplificar as regiões de variações espectrais em relação aos tratamentos de N.

Os perfis espectrais de reflectância em geral variaram em relação ao nível de coleta de dados. Para dados em nível de laboratório, observou-se maior diferenciação dos tratamentos de N na faixa do visível, região entre 450-750 nm e menor na região do infravermelho próximo (800 nm e 1300 nm). Essa condição foi mais evidente no ciclo I (2015) em relação a ciclo II. Para dados em nível de campo, verificou-se maior diferenciação dos tratamentos de adubação na região do infravermelho próximo entre 800 nm e 1300 nm.

Em geral, as modificações no espectro ocorreram de forma mais evidente na região do visível nos dados coletados em nível de folha em laboratório e no infravermelho para dados de dossel em campo. Os tratamentos com adubação reduzida (N1 e N2) apresentaram aumento de refletância de forma mais evidente na região entre 450-750 nm fortemente influenciada pela degradação da clorofila. No infravermelho observou-se a tendência de alta reflectância nas doses N4 e N3 em relação às doses reduzidas N2 e N1. As maiores amplitudes entre os valores foram observadas nesses estádios, que possivelmente deve-se ao fato do melhor aproveitamento de N nas primeiras adubações.

Em relação às variações em função das fases fenológicas para dados de laboratório, verificou-se maiores alterações no espectro nos estádios R3 no ciclo 1 e R1 no ciclo 2. Nos dados de campo foi possível observar de forma mais evidente a variação no tempo. Nos estádios V8 e R1 observaram-se maiores valores de reflectância nos tratamentos N4 e N3, enquanto que a doses N2 e N1 mostram reflectância reduzida.

Figura 13 – Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de folhas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R3 obtidas em laboratório no ciclo I (2015)

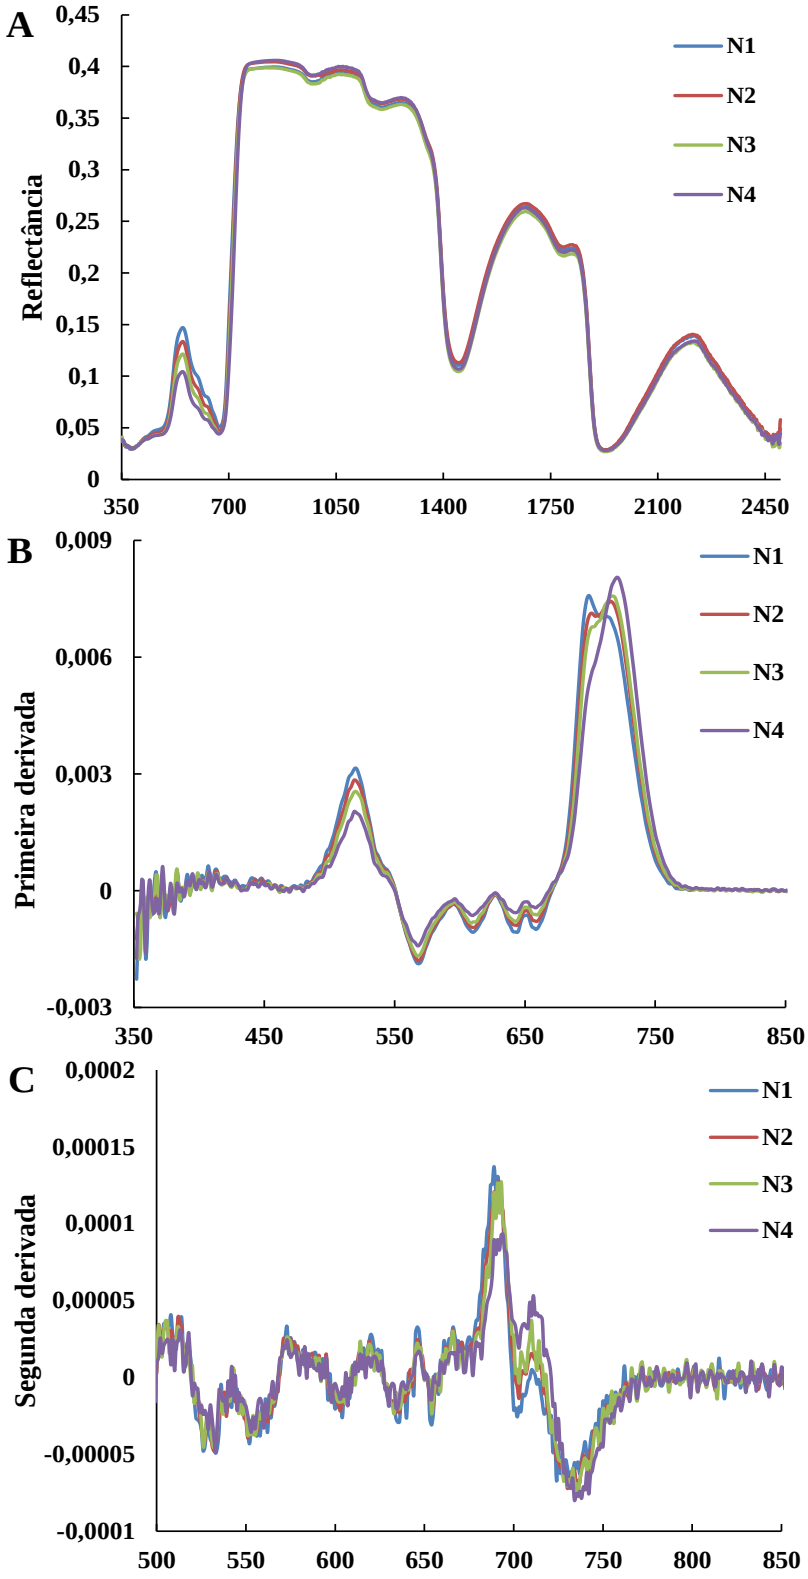


Fonte: elaboração do autor.

Figura 14 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de folhas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento V8 obtidas em laboratório no ciclo II (2016)

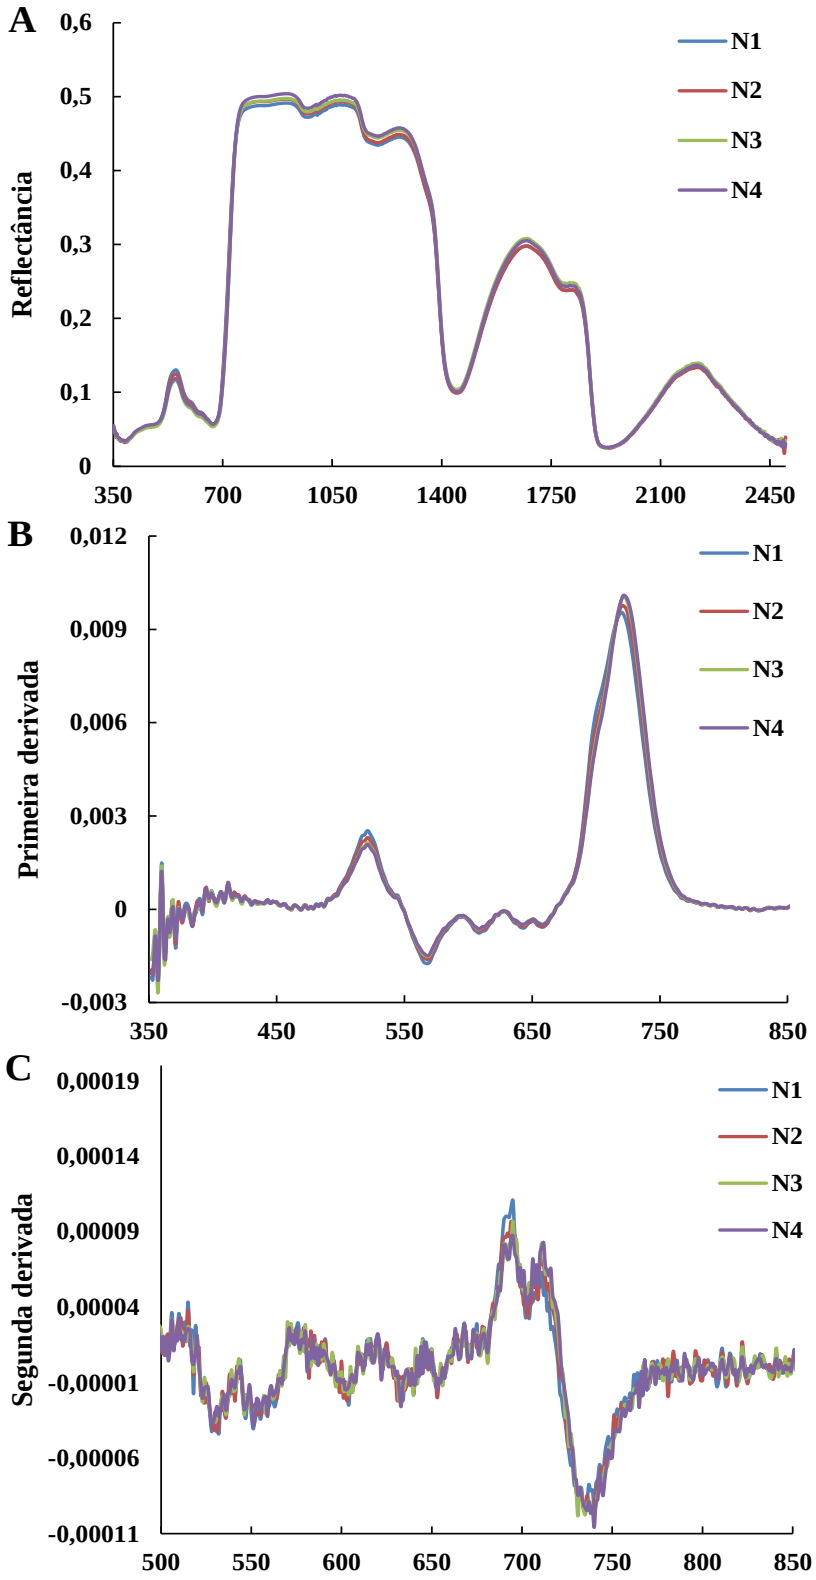


Fonte: elaboração do autor.

Figura 15 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de folhas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R1 obtidas em laboratório no ciclo II (2016)

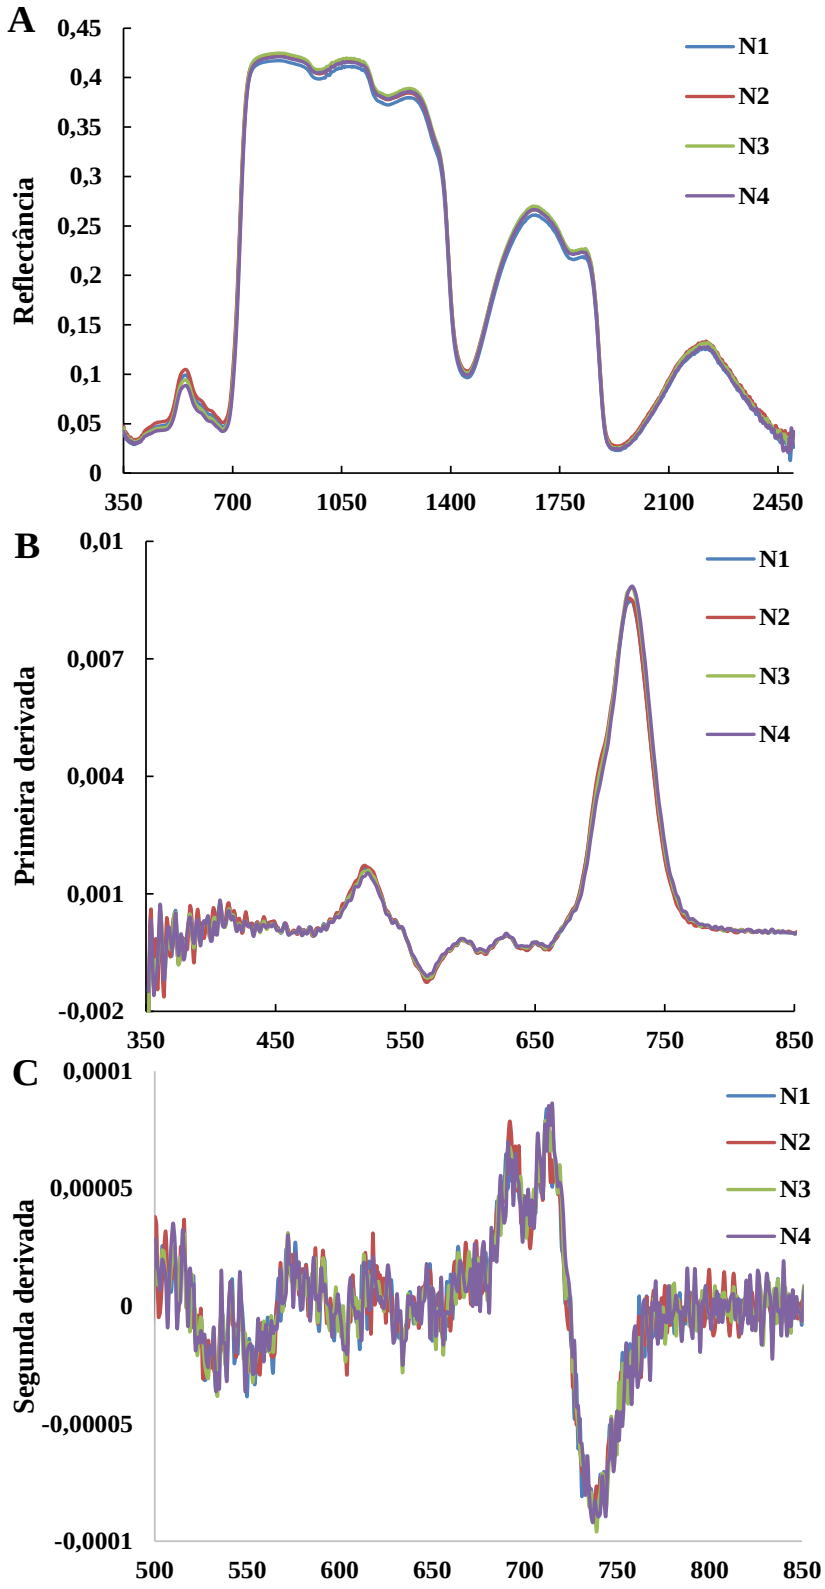


Fonte: elaboração do autor.

Figura 16 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de folhas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R1 obtidas em laboratório no ciclo II (2016)

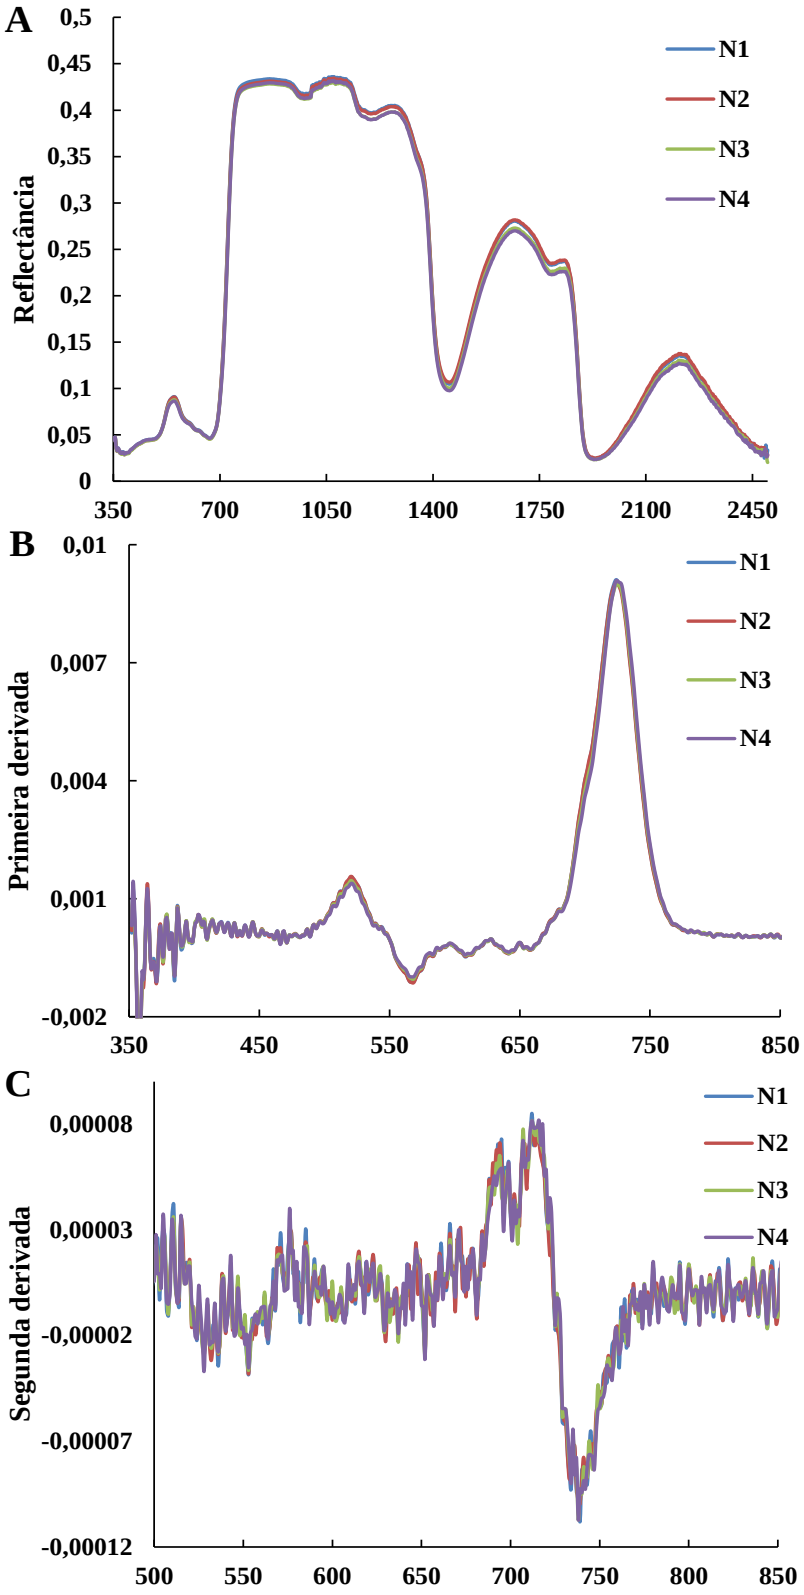


Fonte: elaboração do autor.

Figura 17 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento V3 obtidas em campo no ciclo I (2015)

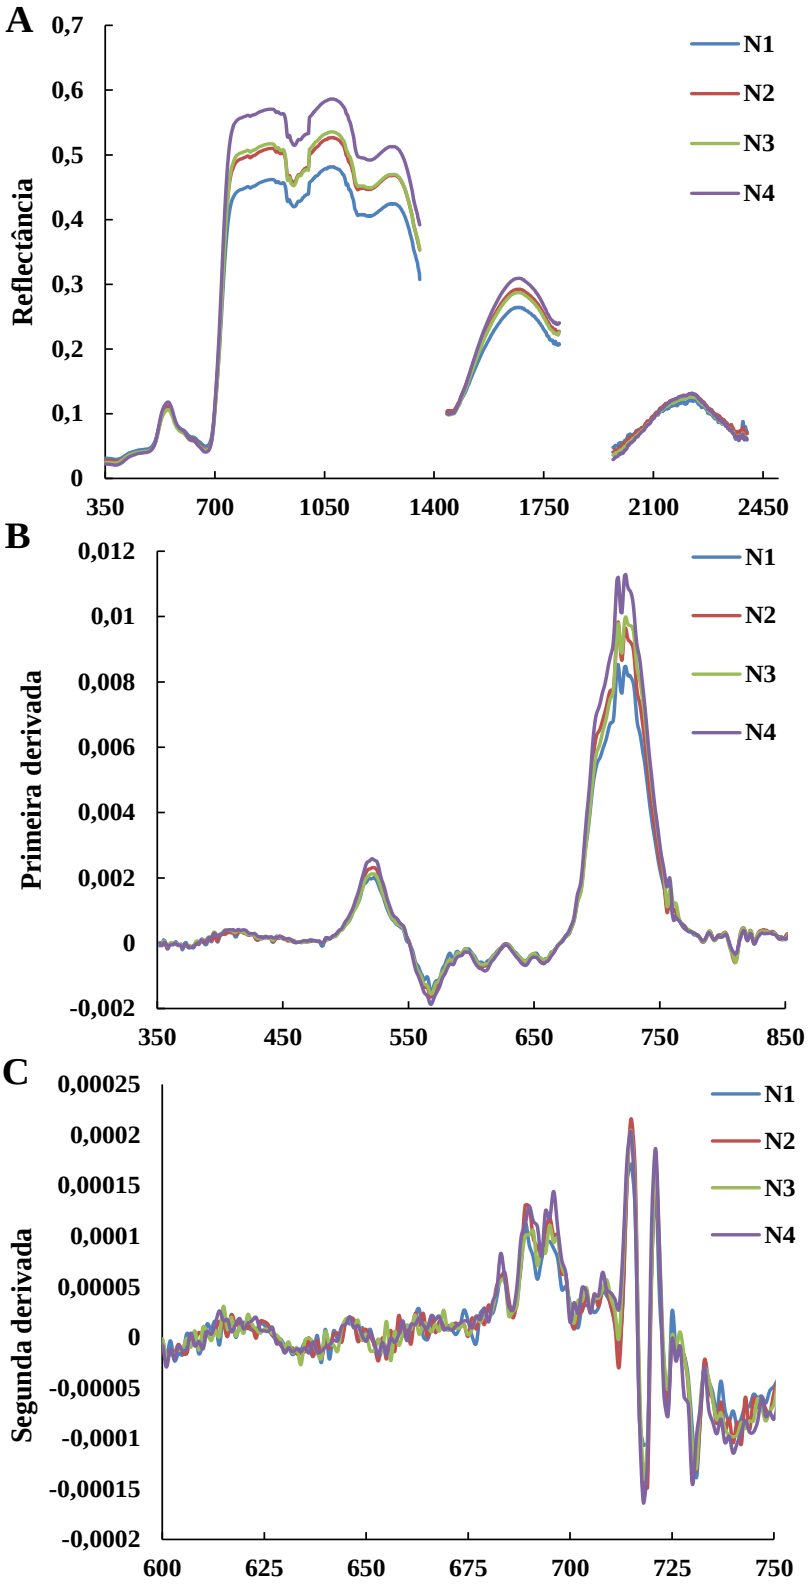


Fonte: elaboração do autor.

Figura 18 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R1 obtidas em campo no ciclo I (2015)

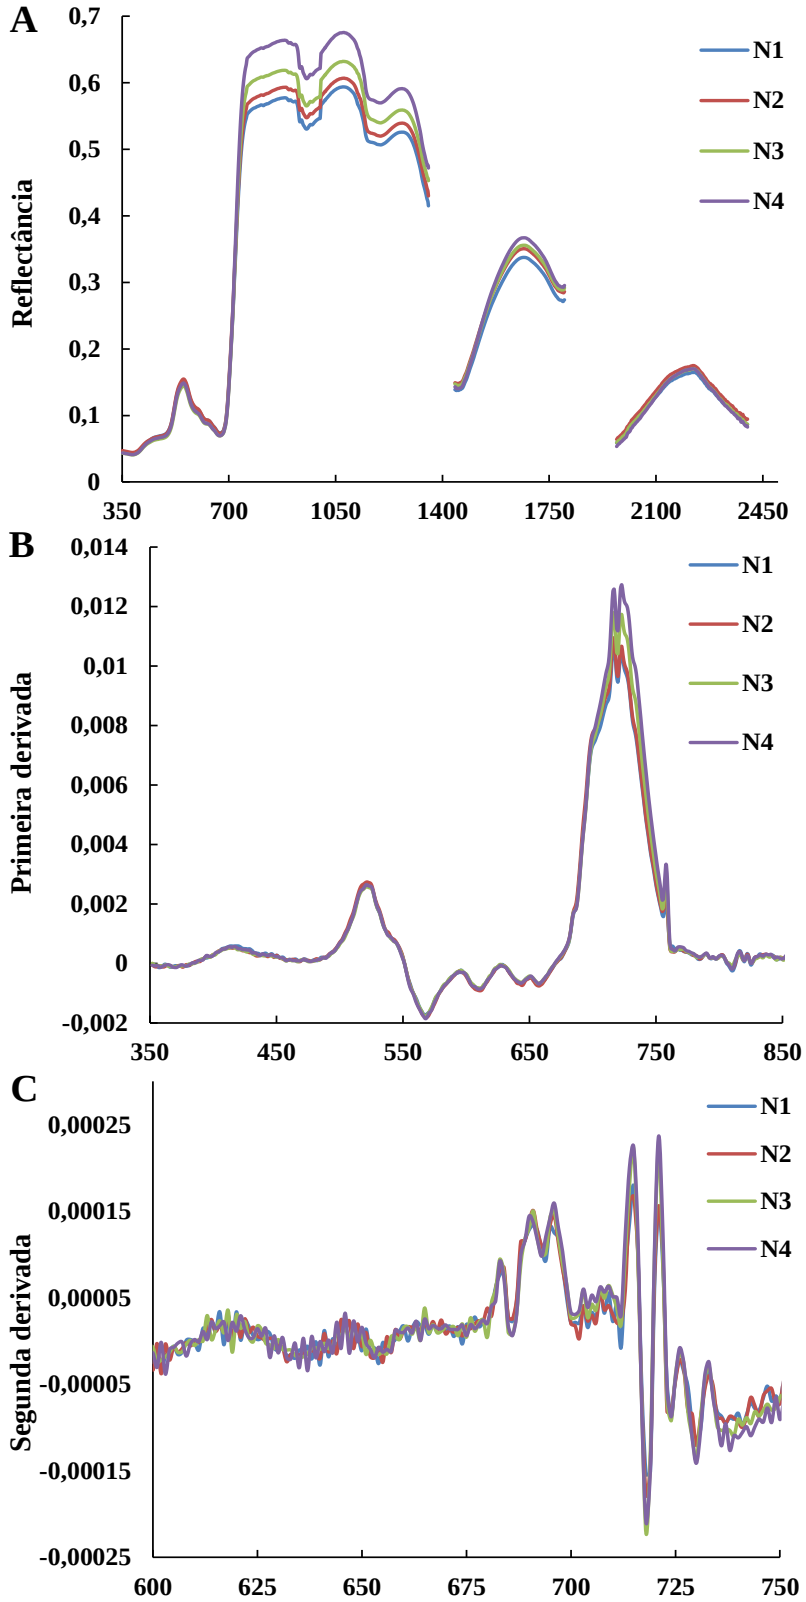


Fonte: elaboração do autor.

Figura 19 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R3 obtidas em campo no ciclo I (2015)

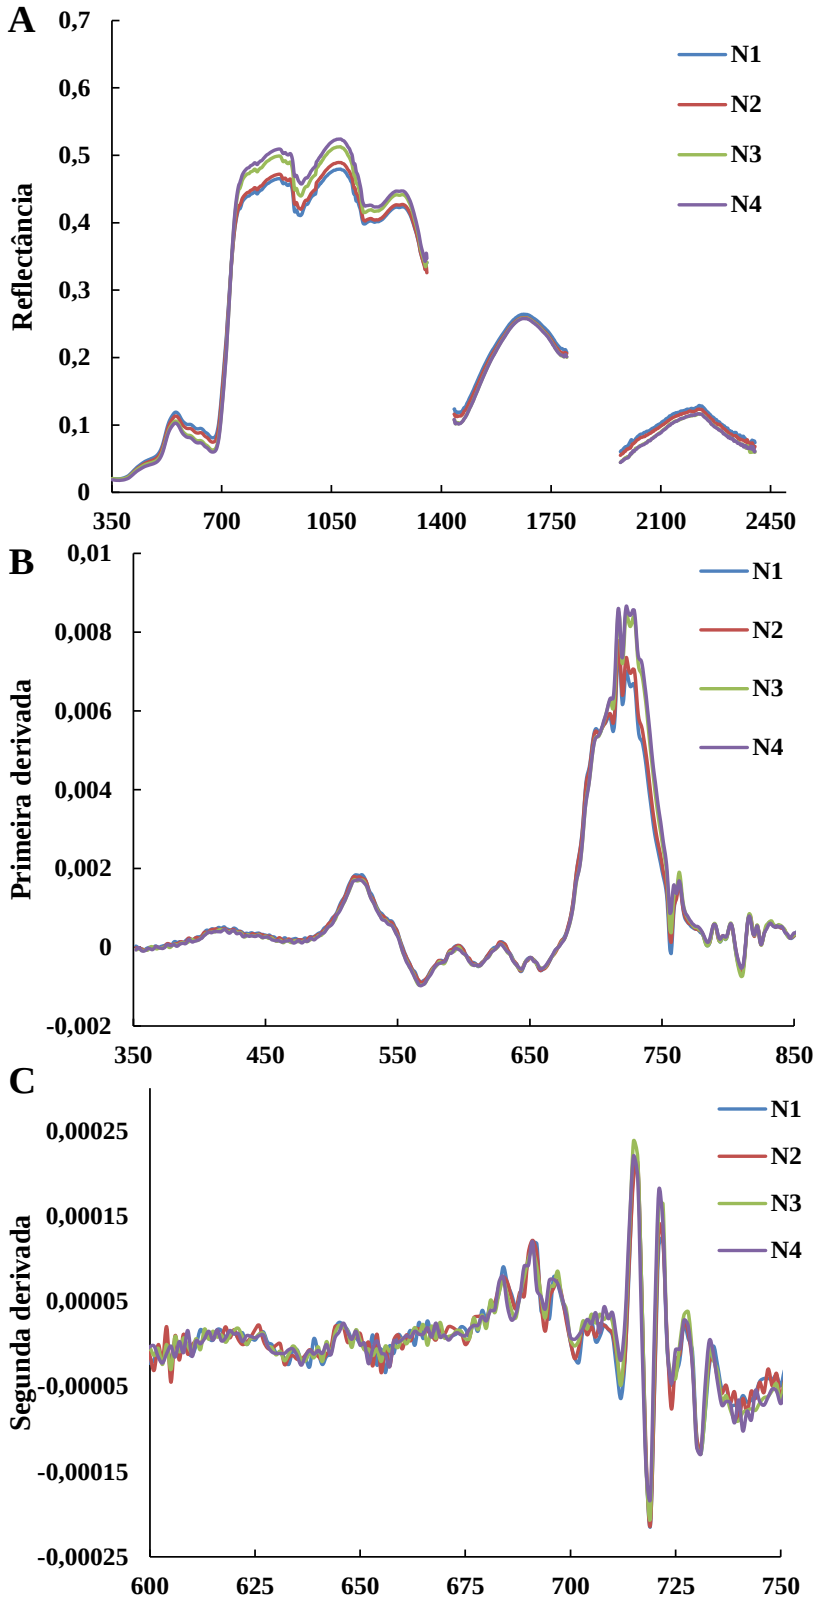


Fonte: elaboração do autor.

Figura 20 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento V8 obtidas em campo no ciclo II (2016)

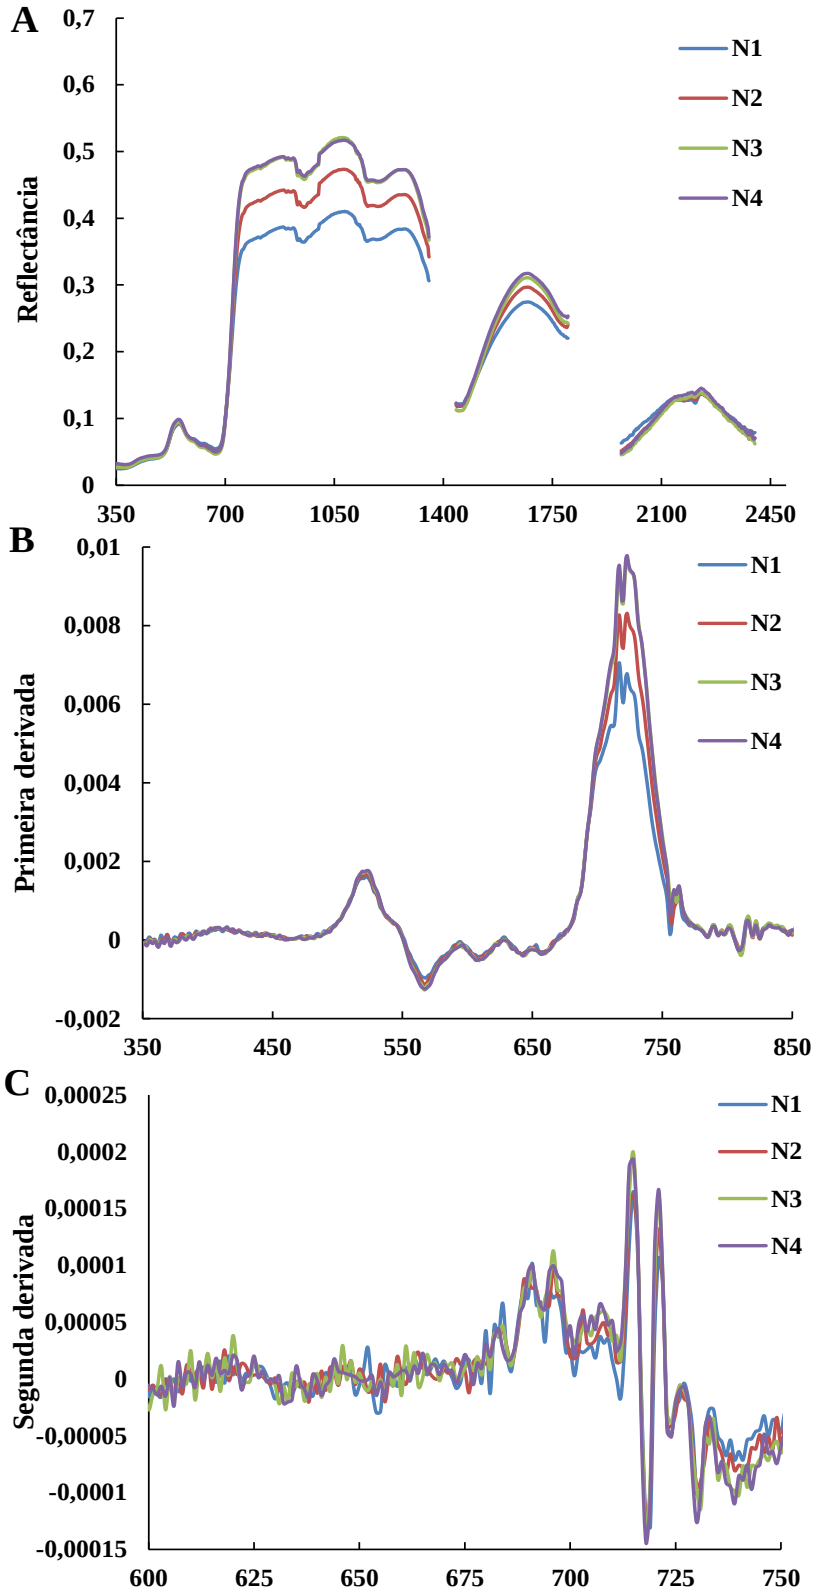


Fonte: elaboração do autor.

Figura 21 - Fator de reflectância (A), Primeira derivada (B) e Segunda derivada (C) de perfis espectrais de dosséis de plantas de milho submetidos a diferentes níveis de adubação nitrogenada no estádio de desenvolvimento R3 obtidas em campo no ciclo II (2016)

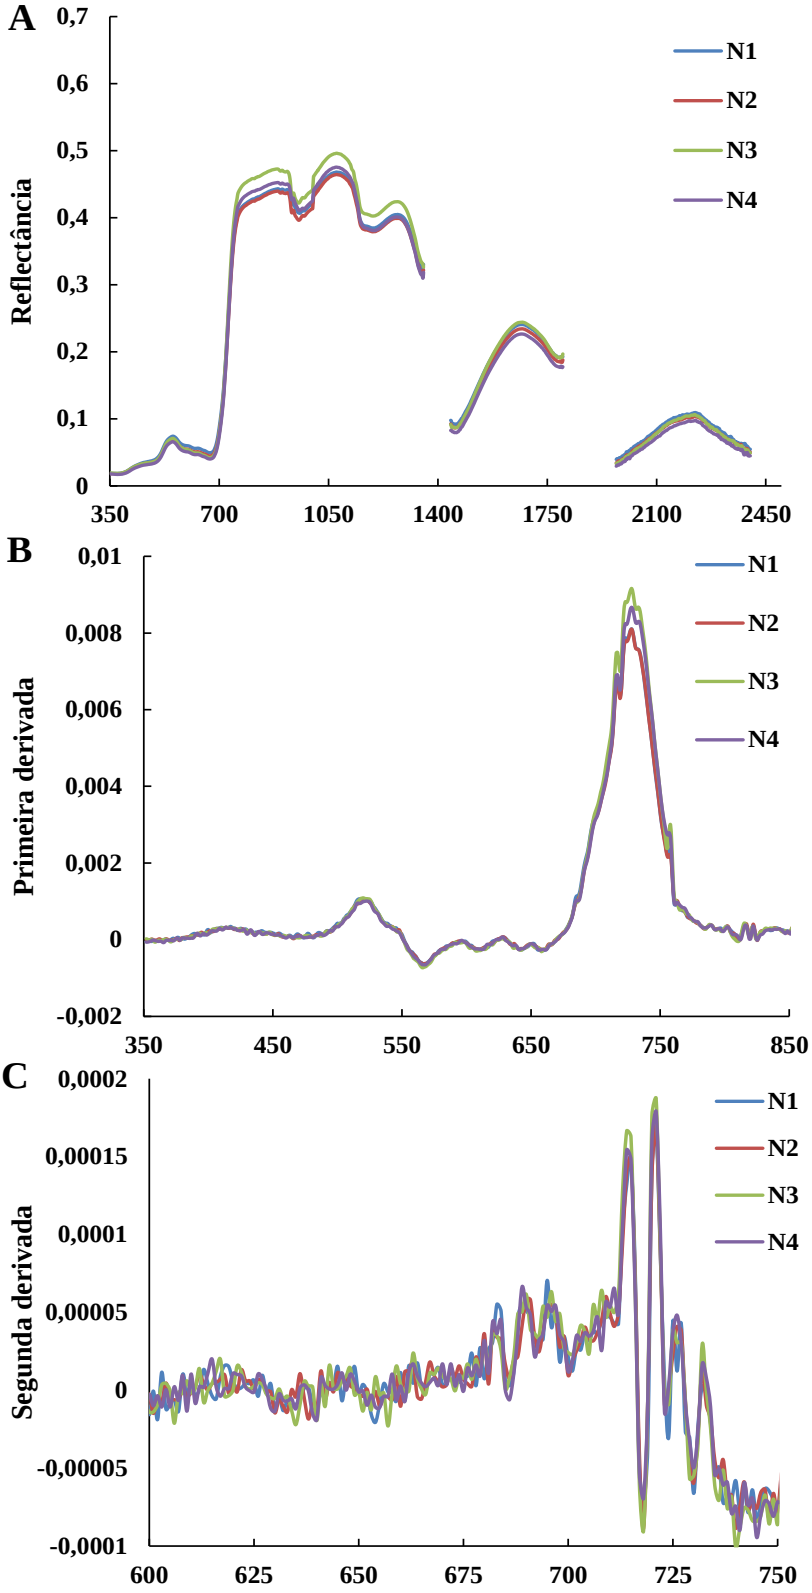


Fonte: elaboração do autor.

Com a aplicação da derivada de primeira ordem, verificou-se maior variação nas regiões correspondentes ao pico de reflectância próximo ao verde (470 nm a 550 nm), com valores variando em torno de 0,001 a 0,0031 para dados de laboratório e 0,001 a 0,0026 para dados de campo. Na faixa correspondente a absorção dos pigmentos de clorofila (720 nm a 750 nm), encontrou-se variações em torno de 0,007 e 0,010 para dados de laboratório e 0,006 e 0,012 para campo.

A segunda derivada evidenciou a resposta dos pigmentos de clorofila entre 700 nm e 725 nm, em função dos tratamentos de N. Para dados de laboratório, as amplitudes verificadas, compreenderam valores entre 0,0009 e 0,00013 no primeiro ciclo (2015) e 0,0004 e 0,00011 no ciclo II (2016). Para dados coletados em campo os valores encontrados permaneceram em torno de 0,00017 e 0,00023 no primeiro ciclo e de 0,00015 e 0,00019 no segundo ciclo de cultivo.

De maneira geral, a diferenciação dos tratamentos de adubação por meio da primeira derivada foi melhor observada para os dados de campo. Na região entre 700 nm e 750 nm foi verificado que os tratamentos N4 e N3 apresentam picos mais elevados em relação aos tratamentos N1 e N2. Na derivada de segunda ordem, os tratamentos de adubação puderam ser diferenciados de maneira melhor nos dados de campo em relação aos de laboratório, em uma escala menor na região entre 700 nm e 725 nm, com os tratamentos mais fertilizados apresentando maiores valores em relação aos tratamentos de redução de N.

***Análise de componentes principais***

Os resultados da análise de componentes principais para os dois conjuntos de dados são mostrados nas Figuras 22 e 23.

Verificou-se que cerca de 93,25% e 95,12% do total da variação explicada nos espectros foi extraída usando as três primeiras componentes principais, para os dados de laboratório e campo respectivamente.

Outros PCs apresentaram menos informações sobre a variabilidade do espectro, no entanto, podem ser ignorados sem perda significativa de informações contidas nos conjuntos de dados originais.

Dessa forma, as três primeiras componentes foram mantidas para a análise da reflectância espectral.

Figura 22 - Variância explicada dos preditores X (A) e Autovalores (B) em função do número de componentes para dados de reflectância de folhas coletados em laboratório (n=256)

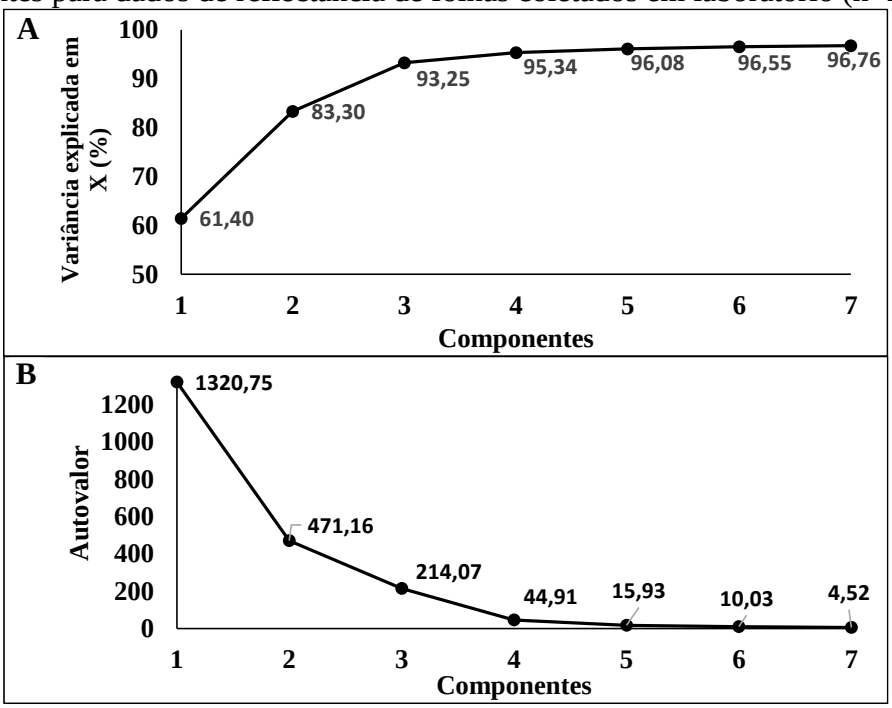


Fonte: elaboração do autor.

Figura 23 - Variância explicada dos preditores X (A) e Autovalores (B) em função do número de componentes para dados de reflectância de folhas coletados em campo (n=320)

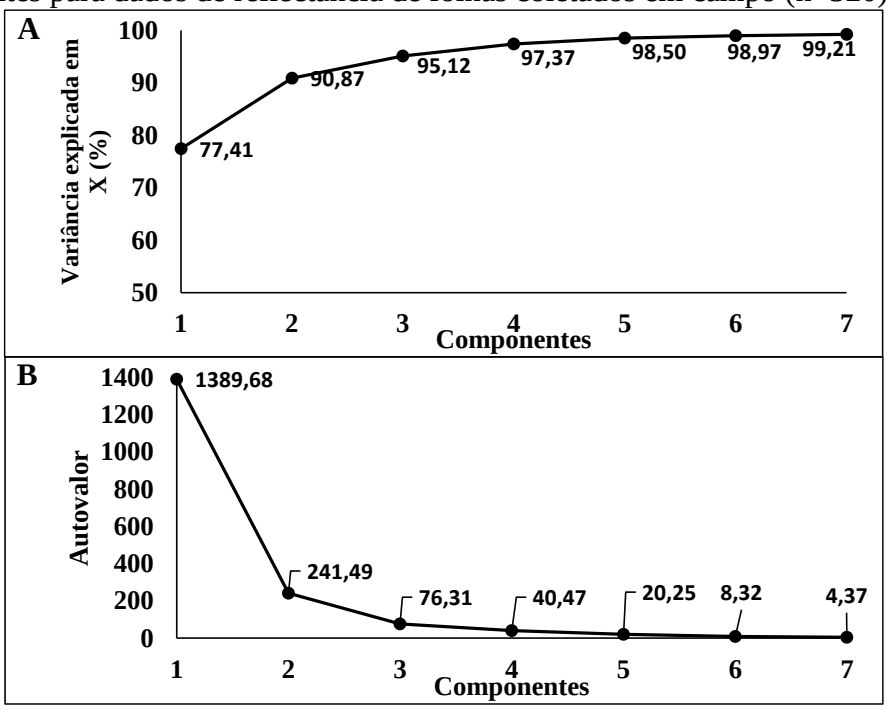


Fonte: elaboração do autor.

Os gráficos de peso de carregamento (*loadings*) e os respectivos coeficientes dos três primeiros PCs para os dados de laboratório e campo são mostrados na Figuras 24 e 25. Os *loadings* e seus coeficientes fornecem a composição das PCs em relação as bandas espectrais (variáveis X), permitindo compreender a influência de cada PC para descrever o espectro.

Para os dados de laboratório, o PC1 foi influenciado principalmente pelo início borda vermelha (por volta de 700 nm) e ao longo de todo o infravermelho e parte do SWIR (750 nm a 2500 nm). O PC2 foi dominado pelas regiões específicas de resposta no verde (550 nm) e absorção do vermelho (por volta de 700 nm) e ainda pelas feições características de água (1400 nm e 1850 nm). A PC3 foi influenciada principalmente no visível entre 500 nm e 600 nm, com um pico considerável próximo ao 700 nm (FIGURA 24).

Para os dados de campo, o PC1 foi influenciado pela reflectância em todas as regiões do espectro, não apresentando uma faixa específica. A PC2 apresentou maior importância na região do infravermelho 750 nm a 1300 nm. A PC3 foi influenciada no visível, com picos máximos em torno de 550 nm e 750 nm e em parte do SWIR em 1750 nm (FIGURA 25).

Figura 24 - Peso de carregamento (*loadings)* (A) e Coeficientes *loadings* (B) para os três primeiros PCs em função do espectro de reflectância para os dados de laboratório

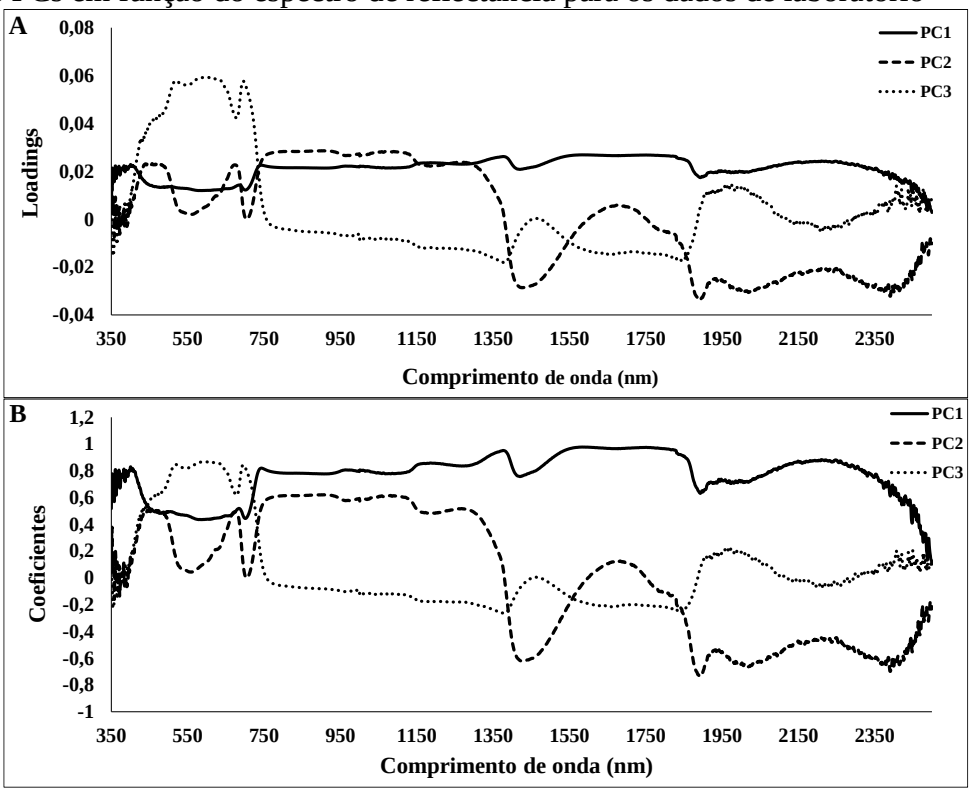


Fonte: elaboração do autor.

Figura 25 - Peso de carregamento (*loadings*) (A) e Coeficientes *loadings* (B) para os três primeiros PCs em função do espectro de reflectância para os dados de campo

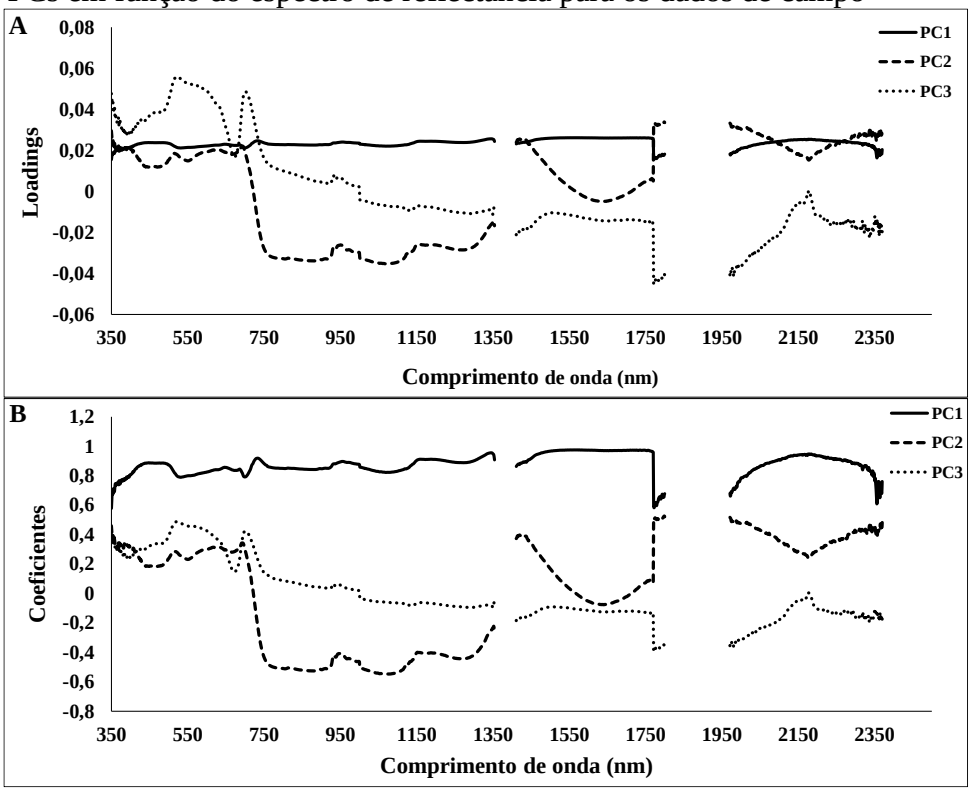


Fonte: elaboração do autor.

## Discussão

Em geral, os padrões de mudança e dinâmica da reflectância de plantas em diferentes tratamentos de N nas faixas do visível (400 nm a 700 nm) e do infravermelho próximo (800 nm a 1300 nm) estão bem estabelecidos na literatura e devem-se principalmente a alterações nos teores de clorofila e na estrutura celular vegetal (MIPHOKASAP *et al.*, 2012; INOUE *et al.*, 2016).

Situações de estresse, tais como nutricional e hídrico, ocasionam a degradação desses pigmentos e consequente, aumento da reflectância na região do visível, mais acentuada na região do verde (DAUGHTRY *et al.*, 2000). Por conseguinte, aumentos da reflectância nessa região especifica do espectro são geralmente relacionados com efeitos de deficiência nutricional. Segundo Zhu *et al.* (2006), a baixa reflectância no visível (460 - 710 nm) e alta no infravermelho próximo (710 - 1220 nm) estão positivamente relacionados ao aumento da concentração de N na folha. Os resultados apresentados mostram que na região do infravermelho (800 nm a 1300 nm) identificou-se com maior evidência, a diferenciação dos tratamentos de adubação. Essa faixa do espectro é influenciada pela estrutura celular do

mesófilo, onde ocorre elevado espalhamento da radiação. Dessa forma, o desenvolvimento vegetativo nas diferentes disponibilidades de N teve efeito considerável na dinâmica da reflectância (SEÇÃO 3.1). Segundo Schlemmer *et al.* (2013), o aumento do índice de área foliar e biomassa resultante de plantas bem fertilizadas, interfere fortemente na resposta espectral, principalmente na região do infravermelho.

Os resultados dos espectros de reflectância no visível e infravermelho de dosséis de plantas de milho sob diferente disponibilidade de N estão de acordo com trabalhos descritos na literatura (SCHLEMMER *et al.*, 2013). A tendência da maior evidência de resposta no infravermelho próximo foi também relatada por Quemada *et al.* (2014) em trabalho com diferentes dosagens de N no milho.

A análise derivativa de primeira ordem, em geral, foi mais eficiente na diferenciação dos tratamentos que a de segunda ordem. As regiões que melhor diferenciaram os tratamentos de adubação são as faixas entre 470 nm a 550 nm e 720 nm a 750, correspondentes a regiões espectrais sensíveis à concentração de pigmentos de clorofila e responsivas ao N foliar (CHU *et al.*, 2014; INOUE *et al.*, 2016).

Em estudos de análise espectral de várias culturas, incluindo o milho, Inoue *et al.*, (2016) encontraram picos mais acentuados em torno de 710 nm, crescente de acordo com o nível de concentração de clorofila. Em experimento de cana-de-açúcar com vários níveis de nitrogênio, Miphokasap *et al.*, (2012) identificaram alta variação da derivada do espectro nas regiões entre 650 - 750 nm, destacando de forma mais evidente os tratamentos de N. Segundo os autores, essa faixa é a mais adequada para a seleção de comprimentos de onda para estimar N foliar. Segundo Corti *et al.* (2017), a aplicação da segunda derivada ao espectro demostra a alteração do conteúdo de N foliar principalmente na região de transição do vermelho e NIR, denominado “borda-vermelha”. O amarelecimento da folha causado por deficiência é o principal responsável pela alteração do espectro derivado, observável na faixa entre 600 nm a 750 nm.

A análise de componentes principais permitiu extrair as informações mais significativas em diferentes regiões do espectro. Os resultados mostraram os três primeiros PCs da reflectância para os dois níveis de coleta de dados, contêm a maior parte das informações características relevantes do espectro. Geralmente, em espectros de vegetação, a análise do espectro pode ser descrita com três PCs sem perda significativa de informações originais (YANG *et al.*, 2016).

A PC1 para os dois conjuntos de dados foi responsável pela quantidade de luz refletida em todos os comprimentos de onda do espectro, com importância mais acentuada na borda vermelha e no infravermelho próximo para dados de laboratório. Resultados semelhantes foram encontrados por Yang *et al.* (2016), para cultura do arroz, com importância destaca da PC1 principalmente no infravermelho. No caso dos dados de campo, o poder refletor da superfície vegetal foi que determinou a importância desse PC. O poder refletor é determinado pela relação da radiação refletida (fluxo ascendente) e a radiação incidente (fluxo descendente), denominado de albedo, sendo um importante parâmetro para monitoramento de culturas agrícolas (BASTIAANSSEN; CHANDRAPALA, 2003; LIANG, 2005). As propriedades da PC1 para dados de campo apresentam grande dependência desse fator. No entanto, o poder refletor pode estar ligado não necessariamente aos tratamentos de adubação nitrogenada, mas a aumentos do índice de área foliar que está fortemente relacionado com o albedo (PENG *et al.*, 2015).

A PC2, mostrou ser influenciada, no visível (350 nm a 750 nm) para ambos os conjuntos de dados (laboratório e campo). Porém a resposta no infravermelho (750 nm a 1300 nm) foi diferenciada entre os conjuntos de dados, com cargas fatoriais positivas para dados de laboratório e negativas para dados coletados em campo. Além disso, nos dados de laboratório, no visível, pôde-se observar picos característico por volta de 550 nm, não perceptível para os dados de campo. Segundo Sun *et al.* (2017) a PC2 para espectros de vegetação é geralmente significativa, na região do visível, cobrindo o espectro de absorção de clorofilas e carotenoides.

A PC3 para os dois conjuntos de dados, mostrou ser influenciada no visível, sendo evidenciados em 550 nm e 750 nm. Também apresentou influência nas faixas específicas de absorção do entorno de 1400 nm e 1800 nm. A tendência semelhante também foi encontrada para espectros na cultura do arroz por Sun *et al.* (2017), no qual atribuíram a resposta da PC3 similar à derivada do espectro. A região especifica de 550 nm, a qual também foi verificada por esses autores, é uma faixa fortemente relacionada a resposta da clorofila (GITELSON *et al.*, 2003). No que diz respeito as cargas fatorais para PC3, foram verificadas cargas positivas no visível, tanto para dados de laboratório como para os de campo (FIGURAS 24 e 25). Diferentemente, em estudos com arroz em diferentes disponibilidades de nitrogênio, a PC3 apresentou cargas fatorais negativas na mesma faixa (YANG *et al.*, 2016).

**Conclusões**

A adubação nitrogenada ocasiona mudanças significativas no espectro de reflectância em plantas de milho. As taxas de fertilização crescentes aumentam a reflectância, principalmente no visível na faixa entre 400 nm a 700 nm e no infravermelho próximo entre 800 nm a 1300 nm.

Os perfis espectrais de reflectância variam em relação ao nível de coleta de dados. Para dados no nível de laboratório, a maior diferenciação dos tratamentos de nitrogênio ocorre na faixa do visível, especificamente na região entre 450-750 nm. Para dados em nível de campo, a maior diferenciação ocorre na região do infravermelho próximo entre 800 nm e 1300 nm.

A análise derivativa de primeira ordem permite ressaltar as regiões sensíveis a tratamentos de nitrogênio foliar evidenciada nas regiões entre 470 nm a 550 nm e 720 nm a 750. Em uma escala mais detalha, a segunda derivada conseguiu evidenciar a resposta de pigmentos de clorofila entre 700 nm e 725 nm, em função dos tratamentos de nitrogênio.

As três primeiras componentes principais são capazes de explicar a maior parte da variação total da resposta espectral de reflectância, com explicação acima de 90%. No entanto, as características dos pesos fatorais das componentes diferem entre os dois níveis de coleta.

A refletividade ao longo de toda faixa espectral (350 nm a 2500 nm) domina a componente de maior relevância (PC1) em dados de dossel (campo), enquanto que em nível de folha (laboratório), essa influência é acentuada do início da borda vermelha (700 nm) e se estende ao longo de todo o infravermelho. A PC2 é influenciada, principalmente no infravermelho entre 750 nm a 1300 nm, ao ponto que a PC3 está associada a resposta espectral do visível em torno de 550 nm e 750 nm

Os níveis de adubação nitrogenada e de coleta de dados interferem fortemente nos perfis espectrais de plantas de milho. A identificação das regiões específicas sensíveis às variações de N foliar, assim como a caracterização dos fatores responsáveis pela variação da resposta espectral, é de grande relevância para estudos relacionados ao uso do sensoriamento remoto hiperespectral para diagnóstico nutricional de plantas.

# REFERÊNCIAS


BASTIAANSSEN, W.G.; CHANDRAPALA, L. Water balance variability across Sri Lanka for assessing agricultural and environmental water use. **Agricultural water management**, v. 58, n. 2, p. 171-192, 2003.

BRO, R.; SMILDE, A. K. Principal component analysis. **Analytical Methods**, v. 6, n. 9, p. 2812-2831, 2014.

CHEN, P.; HABOUDANE, D.; TREMBLAY, N.; WANG, J.; VIGNEAULT, P.; LI, B. New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. **Remote Sensing of Environment**, v.114, p.1987–1997, 2010.

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

CHU, X.; GUO, Y.; HE, J.; YAO, X.; ZHU, Y.; CAO, W.; TIAN, Y. Comparison of different hyperspectral vegetation indices for estimating canopy leaf nitrogen accumulation in rice. **Agronomy Journal**, v. 106, n. 5, p. 1911-1920, 2014.

CILIA, C.; PANIGADA, C.; ROSSINI, M.; MERONI, M.; BUSETTO, L.; AMADUCCI, S.; COLOMBO, R. Nitrogen status assessment for variable rate fertilization in maize through hyperspectral imagery. **Remote Sensing**, v. 6, n. 7, p. 6549-6565, 2014.

CLEVERS, J. G.P.W.; GITELSON, A. A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and-3. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 344-351, 2013.

CORTI, M., GALLINA, P. M., CAVALLI, D., & CABASSI, G. Hyperspectral imaging of spinach canopy under combined water and nitrogen stress to estimate biomass, water, and nitrogen content. **Biosystems Engineering**, v. 158, p. 38-50, 2017.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; DE COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.

GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of plant physiology**, v. 160, n. 3, p. 271-282, 2003.

GITELSON, A. A.; PENG, Y.; ARKEBAUER, T. J.; SCHEPERS, J. Relationships between gross primary production, green LAI, and canopy chlorophyll content in maize: Implications for remote sensing of primary production. **Remote Sensing of Environment**, v. 144, p. 65-72, 2014.

GOODIN, D. G.; HAN, L.; FRASER, R. N.; RUNDQUIST, D. C.; STEBBINS, W. A. Analysis of suspended solids in water using remotely sensed high resolution derivative spectra. **Photogrammetric Engineering & Remote Sensing**, v. 59, n. 4, p. 505-510, 1993.

HAN, Luoheng. Estimating chlorophyll-a concentration using first-derivative spectra in coastal water. **International Journal of Remote Sensing**, v. 26, n. 23, p. 5235-5244, 2005.

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.

HUNT, E. R.; DORAISWAMY, P. C.; MCMURTREY, J. E.; DAUGHTRY, C. S.; PERRY, E. M.; AKHMEDOV, B. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 103-112, 2013.

INOUE, Y.; GUÉRIF, M.; BARET, F.; SKIDMORE, A.; GITELSON, A.; SCHLERF, M.; OLIOSO, A. Simple and robust methods for remote sensing of canopy chlorophyll content: a comparative analysis of hyperspectral data for different types of vegetation. **Plant, cell & environment**, v. 39, n. 12, p. 2609-2623, 2016.

LI, F.; MIAO, Y.; FENG, G.; YUAN, F.; YUE, S.; GAO, X.; CHEN, X. Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. **Field Crops Research**, v. 157, p. 111-123, 2014.

LIANG, Shunlin. **Quantitative remote sensing of land surfaces**. John Wiley & Sons, 2005.

LIU, L., SONG, B., ZHANG, S., & LIU, X. A Novel Principal Component Analysis Method for the Reconstruction of Leaf Reflectance Spectra and Retrieval of Leaf Biochemical Contents. **Remote Sensing**, v. 9, n. 11, p. 1113, 2017.

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.

MIRZAIE, M.; DARVISHZADEH, R.; SHAKIBA, A.; MATKAN, A. A.; ATZBERGER, C.; SKIDMORE, A. Comparative analysis of different uni-and multi-variate methods for estimation of vegetation water content using hyper-spectral measurements. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 1-11, 2014.

MOREIRA, R.C.; GALVÃO, L.S. Variation in spectral shape of urban materials. **Remote Sensing Letters**, v. 01, p. 149-158, mar. 2010.

PENG, J.; FAN, W.; XU, X.; WANG, L.; LIU, Q.; LI, J.; ZHAO, P. Estimating crop albedo in the application of a physical model based on the law of energy conservation and spectral invariants. **Remote Sensing**, v. 7, n. 11, p. 15536-15560, 2015.

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

SAHOO, R. N.; RAY, S. S.; MANJUNATH, K. R. Hyperspectral remote sensing of agriculture. **Current Science**, v. 108, n. 5, p. 848-859, 2015.

SCHLEMMER, M.; GITELSON, A.; SCHEPERS, J.; FERGUSON, R.; PENG, Y.; SHANAHAN, J.; RUNDQUIST, D. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. **International Journal of Applied Earth Observation and Geoinformation**, v. 25, p. 47-54, 2013.

SUN, J., YANG, J., SHI, S., CHEN, B., DU, L., GONG, W., & SONG, S. Estimating Rice Leaf Nitrogen Concentration: Influence of Regression Algorithms Based on Passive and Active Leaf Reflectance. **Remote Sensing**, v. 9, n. 9, p. 951, 2017.

TSAI, F.; PHILPOT, W.; Derivative analysis of hyperspectral data. **Remote Sensing of Environment**, v. 66, n. 1, p. 41-51, 1998.

XIA, T.; MIAO, Y.; WU, D.; SHAO, H.; KHOSLA, R.; MI, G. Active optical sensing of spring maize for in-season diagnosis of nitrogen status based on nitrogen nutrition index. **Remote Sensing**, v. 8, n. 7, p. 605, 2016.

YANG, J.; DU, L.; SUN, J.; ZHANG, Z.; CHEN, B.; SHI, S.; SONG, S. Estimating the leaf nitrogen content of paddy rice by using the combined reflectance and laser-induced fluorescence spectra. **Optics express**, v. 24, n. 17, p. 19354-19365, 2016.

ZHU, Y.; LI, Y.; FENG, W.; TIAN, Y.; YAO, X.; CAO, W. Monitoring leaf nitrogen in wheat using canopy reflectance spectra. **Canadian Journal of Plant Science**, v. 86, n. 4, p. 1037-1046, 2006.

# 5 ANÁLISE QUANTITATIVA DE NITROGÊNIO NA CULTURA DO MILHO A PARTIR DA REFLECTÂNCIA

## RESUMO

A concentração do nitrogênio (N) nas folhas é um importante indicador da sanidade das culturas agrícolas, desempenhando papel fundamental no metabolismo fotossintético e na nutrição das plantas. Assim, a quantificação do N é relevante para a previsão de produtividade e melhoria do manejo de aplicação de fertilizantes. Portanto, objetivou-se avaliar a utilização de espectroscopia de reflectância para estimar a concentração de nitrogênio foliar na cultura do milho irrigado (*Zea mays* L.). Para tanto, um experimento com delineamento em blocos aleatorizados com esquema de parcelas subdivididas e quatro repetições foi adotado. Os tratamentos de irrigação aplicados nas parcelas foram compostos de quatro níveis: 80, 90, 100 e 110% do requerimento hídrico, baseadas na capacidade de campo do solo e os níveis de N, distribuídos nas subparcelas nos níveis: 0, 60, 120 e 180 kg $ha^{-1}$. Foram realizadas medidas radiométricas e determinada a concentração de N foliar nos estádios V8, R1 e R3 da cultura nos níveis de campo e de laboratório. Os modelos preditivos de N foram obtidos por regressões lineares de bandas individuais (BI), índice normalizado de N (NDNI) e regressão por mínimos quadrados parciais (PLSR). Os melhores resultados para a quantificação do N foram obtidos com os modelos PLSR de laboratório no estádio R1 ($R^2$ = 0,82 e RMSEP = 0,190). Usando dados em nível de campo o melhor resultado foi obtido pelo NDNI (762 nm e 684 nm) para o estádio R3 ($R^2$ = 0,78 e RMSE = 0,200). A modelagem foi influenciada pelos estádios fenológicos e pelo tipo de coleta de dados, o que reforça a importância do ajuste de modelos preditivos em função das diferentes fases de crescimento da cultura.

**Palavras-chave**: NDNI. Índice de nutrição. *Zea mays* L. PLSR.

## ABSTRACT

The concentration of nitrogen (N) in the leaves is an important indicator of the sanity of the agricultural crops, playing a fundamental role in the photosynthetic metabolism and in the nutrition of the plants. Thus, the quantification of N is relevant for predicting productivity and

improving the management of fertilizer application. The objective of this study was to evaluate the use of reflectance spectroscopy to estimate leaf nitrogen concentration in irrigated maize *(Zea mays* L.). For this, an experiment with a randomized block design with subdivided plots and four replications was adopted. The irrigation treatments applied in the plots were composed of four levels: 80, 90, 100 and 110% of the water requirement, based on the soil field capacity, and the N levels, distributed in the subplots at levels 0, 60, 120 and 180 kg $ha^{-1}$. Radiometric measurements were performed and the concentration of leaf N at the V8, R1 and R3 stages of the culture at the field and laboratory levels was determined. The predictive models of N were obtained by linear regressions of individual bands (BI), normalized N index (NDNI) and partial least squares regression (PLSR). The best results for the N quantification were obtained with the PLSR laboratory models in the R1 stage ($R^2$ = 0.82 and RMSEP = 0.190). Using field-level data the best result was obtained by the NDNI (762 nm and 684 nm) for the R3 stage ($R^2$ = 0.78 and RMSE = 0.200). Modeling was influenced by the phenological stages and the type of data collection, which reinforces the importance of the adjustment of predictive models as a function of the different phases of crop growth.

**Keywords**: NDNI. Nutrition index. *Zea mays* L. PLSR.

## Introdução

O milho (*Zea mays* L.) está entre as culturas anuais mais cultivadas em nível mundial, assumindo papel importante no cenário internacional da produção de alimentos (FAO, 2015). A produção em larga escala exige extensas áreas de cultivo, o que a torna uma das principais culturas responsáveis pela utilização de insumos agrícolas. As principais demandas estão relacionadas à disponibilidade de nutrientes e água, pois tais fatores comprometem processos fisiológicos que afetam o crescimento da cultura (GONZALEZ-DUGO *et al.*, 2010).

Dentre os elementos minerais essenciais, o nitrogênio (N) é o nutriente exigido em maior quantidade pela cultura do milho, limitando o crescimento, capacidade fotossintética e produtividade de grãos (WEI *et al.*, 2016; TRACHSEL *et al.*, 2016). Na maioria dos sistemas agrícolas, as altas taxas de aplicação de fertilizantes a base de N têm gerado discussões em torno de questões ambientais, pelo elevado potencial de contaminação de águas superficiais e subterrâneas por nitrato, em virtude de perdas por lixiviação (JIA *et*

*al.*, 2014). Assim, técnicas que visam o manejo racional de N têm ganho interesse por melhorar o rendimento da cultura (LENKA *et al.*, 2013).

Nesse contexto, estudos recentes mostram que técnicas de sensoriamento remoto são eficazes na estimativa do estado nutricional de plantas de forma não destrutiva em várias culturas (SHI *et al.*, 2015). A quantificação de componentes bioquímicos como pigmentos fotossintéticos e N é amplamente investigada na cultura do milho (SCHLEMMER *et al.*, 2013; CILIA *et al.*, 2014). A estimativa da concentração de N na folha por meio de índices espectrais possui grande potencial para o monitoramento e determinação das necessidades reais de nutrientes para a cultura (ZHOU *et al.*, 2016).

Em relação a uma abordagem detalhada do espectro eletromagnético, dados hiperespectrais têm sido utilizados para a análise de regiões especificas relacionada com a condição nutricional de plantas (CORTI *et al.*, 2017). As informações espectrais em diversos comprimentos de onda permitem melhor identificação de diferentes tipos de alvos e uma maior precisão na construção de índices de bandas curtas relacionados ao status nutricional (LI *et al.*, 2014). As faixas espectrais do visível (VIS) e do infravermelho próximo (NIR) são as principais regiões onde se é possível à identificação das alterações na reflectância da vegetação em função da adubação. No VIS as alterações devem-se principalmente a degradação de pigmentos, especialmente da clorofila, caracterizando o aumento da reflectância no verde (CHEN *et al.*, 2010). As respostas relacionadas a esses pigmentos são os principais parâmetros que influenciam espectral reflectância em plantas submetidas a diferentes disponibilidades de N (CILIA *et al.*, 2014). Uma dessas mudanças características é o aumento da reflectância na região entre 550 nm e 715 nm com a redução do N foliar (DAUGHTRY *et al.*, 2000). Do mesmo modo, os padrões de absorção próxima ao vermelho (670 nm) são amplamente explorados em estudos sobre deficiência de N em plantas (HUNT *et al.*, 2013).

Na região do NIR, o espectro é influenciado pela estrutura celular do mesófilo, onde ocorre elevado espalhamento da radiação eletromagnética incidente no dossel das plantas (HEEGE *et al.*, 2008). Dessa forma, mudanças estruturas no tecido foliar devido a variações no suprimento nutricional, a exemplo da disponibilidade de N, tem efeito considerável na reflectância dessa faixa (SCHLEMMER *et al.*, 2013). Adicionalmente, a posição da borda vermelha, faixa entre (680-780 nm), tem sido utilizada como um dos principais parâmetros para identificar plantas estressadas por deficiência nutricional (CHO;

SKIDMORE, 2006). Estudos recentes mostram a alta sensibilidade dessa faixa em relação a mudanças nas concentrações de N foliar (BASSO *et al.*, 2016; WANG *et al.*, 2016).

A maioria dos índices de nutrição concentra-se na busca de comprimentos de ondas (bandas) sensíveis a concentração de N na vegetação. Dentre as técnicas empregadas para a obtenção das bandas de interesse, os métodos empírico-estatísticos são largamente utilizados para estimativa de N foliar a partir de dados de sensoriamento remoto (WANG *et al.*, 2016).

Pela simplicidade de aplicação, o método por diferença normalizada entre dados provenientes de faixas espectrais distintas é bastante utilizado para estimativa de N (FENG *et al.*, 2015; WANG e WEI, 2016). Alternativamente, métodos de regressão como o stepwise (SMLR), mínimos quadrados parciais (PLSR) e principal componente regression (PCR) têm obtidos resultados convincentes para esse tipo de estimativa (RYU *et al.*, 2011; YU *et al.*, 2013; WANG *et al.*, 2017).

Em relação à PLSR, esse método é amplamente indicado para a construção de modelos de previsão quando se tem elevado número de fatores altamente colineares (TOBIAS, 1995). A colinearidade é um fator inerente aos dados de sensoriamento remoto hiperespectral, dessa forma, a possibilidade de analisar conjuntamente grande número dados provenientes de diferentes faixas espectrais, suas fontes de variação e a resolução do problema da colinearidade entre elas, são as principais vantagens desse método.

Segundo Atzberger *et al*. (2010), a PLSR fornece um modelo de regressão, onde toda a informação espectral é analisada de forma ponderada, mostrando ser adaptado para lidar com fatores de confusão na construção de índices de vegetação frente a outros métodos de regressão como o principal component regression (PCR) e stepwise multiple linear regression (SMLR).

Diante do exposto, este trabalho tem como principais objetivos: i) avaliar o uso de dados hiperespectrais, obtidos por espectroscopia de reflectância de campo e laboratório, para estimar a concentração de N foliar na cultura do milho; ii) avaliar o desempenho de técnicas de regressão para a obtenção de modelos preditivos do teor de N foliar, em condições de campo e laboratório; iii) desenvolver um novo índice de vegetação de banda estreita melhorado para o monitoramento do status de N na cultura do milho e iv) investigar como os estádios de crescimento e o nível de coleta de dados influenciam na modelagem de N.

## Material e métodos

### *Caracterização da área experimental e tratamentos*

O estudo foi conduzido em uma área experimental no Laboratório de Hidráulica e irrigação do Departamento de Engenharia Agrícola da Universidade Federal do Ceará, Campus do Pici, localizada no município de Fortaleza, CE, coordenadas 3º45' S e 38º 33' W, e altitude de 19 m. Segundo a classificação de Köppen, a área do experimento está localizada em uma região de clima Aw'. O solo da área é classificado como argissolo vermelho-amarelo de textura franco-argilo-arenosa.

As plantas de milho (*Zea mays* L.) híbrido AG 1051, foram cultivadas no período de setembro a dezembro de 2015 (ciclo I) e de novembro de 2016 a janeiro de 2017 (ciclo II). As atividades de replantio e desbaste foram realizadas sete e quinze dias após o plantio, respectivamente.

O controle de plantas invasoras foi realizado em pré-emergência com aplicação de glifosato, e pós-emergência com antrazina, além de capinas manuais complementares.

O controle fitossanitário ocorreu sempre que detectado a ocorrência de pragas na cultura. A colheita de espigas foi realizada 75 dias após o plantio.

O delineamento adotado foi o de blocos aleatorizados, num esquema de parcelas subdivididas replicado quatro vezes, com a parcela principal composta de quatro níveis lâminas de irrigação L1= 80%, L2 = 90%, L3 = 100% e L4 = 110% do requerimento hídrico, baseados na umidade de capacidade de campo (CC) e a subparcela com quatro doses de adubação nitrogenada (N0 = 0 kg, N60 = 60 kg N120 = 120 kg e N180 = 180 kg de N por hectare) considerando a dose de 120 kg $ha^{-1}$ a quantidade necessária segundo análise de solo.

A fonte de N utilizado foi a Ureia CO(NH2)2. A adubação foi complementada em todos os tratamentos com 60 kg $ha^{-1}$ de P2O5, 70 kg $ha^{-1}$ K2O e 30 kg $ha^{-1}$ de FTE BR 12.

A irrigação foi realizada por um sistema de gotejamento e manejada por meio de sensores capacitivos de umidade.

A descrição detalhada dos tratamentos de lâminas de irrigação e doses de adubação nitrogenada encontra-se na Tabela 10.

Tabela 10 - Descrição dos tratamentos

| Tratamento | Porcentagem da capacidade de campo (%) | Lâmina total de água aplicada ($m^3$ $ha^{-1}$) Ciclo I - 2015 | Lâmina total de água aplicada ($m^3$ $ha^{-1}$) Ciclo II - 2016 | Quantidade de N aplicado (kg $ha^{-1}$) |
|---|---|---|---|---|
| L1N1 | 80 | 3596 | 3693 | 0 |
| L1N2 | 80 | 3596 | 3693 | 60 |
| L1N3 | 80 | 3596 | 3693 | 120 |
| L1N4 | 80 | 3596 | 3693 | 180 |
| L2N1 | 90 | 3958 | 3928 | 0 |
| L2N2 | 90 | 3958 | 3928 | 60 |
| L2N3 | 90 | 3958 | 3928 | 120 |
| L2N4 | 90 | 3958 | 3928 | 180 |
| L3N1 | 100 | 4853 | 4335 | 0 |
| L3N2 | 100 | 4853 | 4335 | 60 |
| L3N3 | 100 | 4853 | 4335 | 120 |
| L3N4 | 100 | 4853 | 4335 | 180 |
| L4N1 | 110 | 5557 | 5060 | 0 |
| L4N2 | 110 | 5557 | 5060 | 60 |
| L4N3 | 110 | 5557 | 5060 | 120 |
| L4N4 | 110 | 5557 | 5060 | 180 |

Fonte: elaboração do autor.

***Coleta de dados espectrais***

A obtenção de dados espectrais foi realizada utilizando o espectrômetro FieldSpec Pro FR 3 (Analytical Spectral Devices Inc.), que opera na região de 350 a 2500 nm, com resolução de 1 nm em laboratório e em campo. Em laboratório, as leituras foram feitas em sala escura sem interferência da luz externa. A distância do sensor ao alvo foi de 5 cm, a distância da fonte luminosa (lâmpada de 250 Watts) ao alvo foi de 70,7 cm, com ângulo zenital de 45° e a distância da superfície do piso a fonte luminosa 50 cm (FIGURA 10). Foram realizadas, para cada amostra, três leituras em diferentes partes da folha, com a finalidade de fazer uma varredura completa do alvo, sendo considerada a média das três leituras.

Em campo, as leituras foram realizadas a uma altura de 70 cm do topo do dossel das plantas, procedendo três aferições por planta. A aquisição de dados ocorreu no período entre as 10:00 hs – 14:00 hs, sempre em dias com ausência de nebulosidade. Posteriormente, os dados espectrais gerados em número digital (ND) foram convertidos em reflectância utilizando o aplicativo ViewSpecPro 6.2. A descrição do número de coletas encontra-se na Tabela 9.

***Dados de concentração de N foliar***

Posteriormente à aquisição de dados espectrais, as folhas foram coletadas e transportadas para laboratório para determinação de N foliar. Foram coletadas ao todo 64 amostras em três estádios de desenvolvimento da cultura: i) estádio V8 (vegetativo); ii) estádio R1(pendoamento) e iii) estádio R3 (grão pastoso) ao longo de dois ciclos de produção: 2015 (ciclo I) e 2016 (ciclo II), totalizando 192 amostras para cada ciclo.

O material foi manuseado em sacos de papel, secos em estufa de circulação de ar forçada a 60° C até atingir peso constante, trituradas em moinho tipo Willey (modelo MA 340, Marconi, BR), pesadas em balança de precisão e armazenadas em sacos plásticos à temperatura ambiente para posterior análise química. A solubilização das amostras de tecido vegetal foi realizada por meio de digestão sulfúrica e o N total determinado pelo método semi-micro Kjeldahl. Todos os procedimentos de análise foram realizados no Laboratório de Relações Água, Solo e Planta do Departamento de Engenharia Agrícola – DENA/UFC.

***Análises estatísticas***

A normalidade dos dados foi avaliada pelo teste de Kolmogorov-Smirnov ($\alpha$ de 0,05). Para desenvolver os modelos estatísticos quantitativos da concentração de N foliar a partir dos dados de reflectância, foram usadas as seguintes estratégias: regressões lineares usando bandas individuais, o índice normalizado de N (NDNI) e regressão por mínimos quadrados parciais (PLSR). A melhor banda individual foi obtida através da correlação de Pearson ($r$) entre as bandas de espectro e concentração de N foliar. Para formulação do NDNI, foram determinados dentro do espectro das amostras de calibração, os melhores posicionamentos de bandas para descrever a relação entre a razão da diferença normalizada e o N foliar. Esse índice de vegetação foi obtido a partir de um processo iterativo em ambiente Matlab, onde cada banda do espectro foi combinada com as demais (EQUAÇÃO 13) para escolher a combinação com maior coeficiente de determinação ($R^2$). Em seguida, foi feita uma equação de regressão para o índice normalizado *vs* N foliar para o resultado mais significativo das amostras de calibração. Para todos os modelos foram utilizados 2/3 para calibração (48 amostras) das equações lineares e 1/3 restante para validação (16 amostras).

$$NDNI=\frac{(\rho_j - \rho_i)}{(\rho_j + \rho_i)} \quad (13)$$

Onde: $\rho_j$ e $\rho_i$ são reflectâncias de quaisquer dois comprimentos de ondas do espectro e NDNI : Índice de Nitrogênio por Diferença Normalizada.

A regressão por mínimos quadrados parciais (PLSR) tem sido largamente utilizada em diversas áreas do conhecimento para a calibração de modelos preditivos, incluindo dados de espectroscopia (WOLD *et al.,* 2001). Em dados espectrais, o algoritmo PLSR seleciona fatores ortogonais que maximizam a covariância entre as variáveis preditoras X (espectro) e a variável resposta Y (atributo químico, no caso desse trabalho, a concentração de N foliar). O PLSR decompõe ambas as variáveis **X** e **Y** e encontra novos componentes (escores), chamados de variáveis latentes, que são ortogonais. A ideia geral da PLSR é tentar extrair esses fatores latentes, representando o máximo de variação quanto possível. Em seguida, a regressão é calculada entre essas novas componentes das variáveis **X** e **Y**.

$$\mathbf{X=TP+E} \quad (14)$$

$$\mathbf{Y=TQ+F} \quad (15)$$

Em que, **T** = vetores de escores calculados, **P** = *loadings* do espectro, **Q** = *loadings* da concentração de N foliar e **E** e **F** são os resíduos.

A determinação do número ótimo de fatores a serem utilizados para a calibração do modelo foi realizada por meio da validação cruzada *leave-one-out*. A escolha do modelo utilizado para predição de N foi feita comparando-se os parâmetros do coeficiente de determinação ($R^2$) e raiz do erro médio quadrático (RMSE) da validação cruzada, buscando o máximo de correlação entre **X** e **Y**.

Os modelos de bandas individuais, os índices NDNI e os modelos preditivos PLSR foram calibrados e validados utilizando a proporção de 2/3 para calibração (n= 48 amostras) e 1/3 para validação (n=16 amostras) (FIGURA 26). A abordagem se deu separadamente para cada estádio fenológico estabelecido (V8, R1 e R3) e ciclo de colheita (2015 e 2016), com dados de campo e de laboratório.

Figura 26 - Fluxograma de procedimentos de obtenção dos modelos preditivos

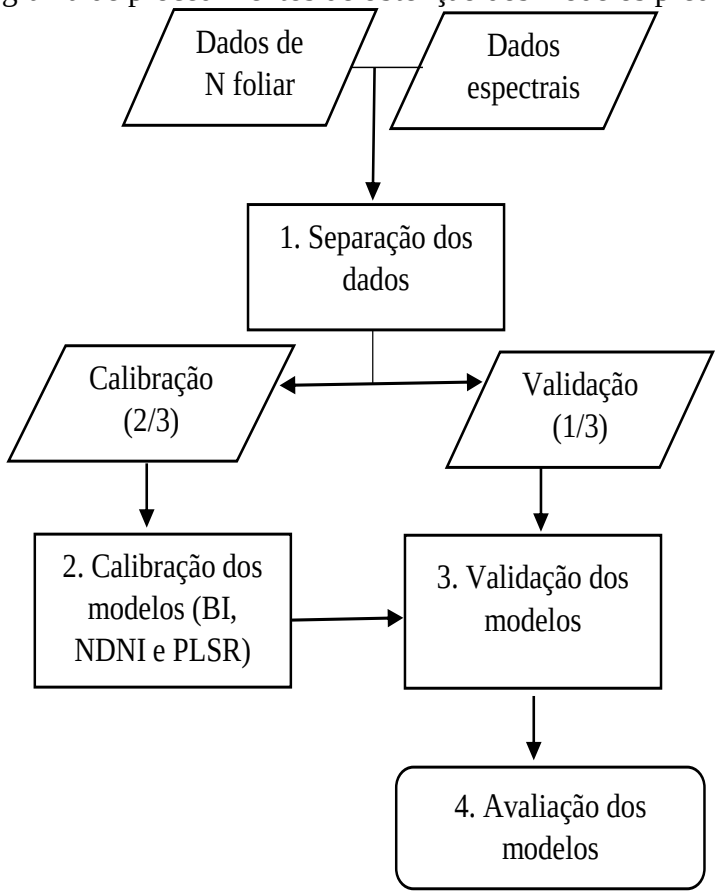


Fonte: elaboração do autor.

A avaliação dos modelos foi realizada por meio das métricas de coeficiente de determinação ($R^2$) e erro médio quadrático (RMSE) de acordo com as equações 16 e 17:

$$R^2=1-\sum_{j=1}^{N}\left(y_j^{'}-y_i\right)^2 / \sum_{j=1}^{n}(y_j^{'}-\bar{y})^2 \quad (16)$$

$$RMSE=\sqrt{\frac{\sum_{j=1}^{N}\left(y_j^{'}-y_i\right)^2}{N}} \quad (17)$$

Em que, $y_j$ e $y_j'$ são os valores medidos e estimados pelo modelo, respectivamente, $\bar{y}$ é a médias dos valores observados, e $N$ o número de observações.

O tratamento dos dados, bem como o desenvolvimento, calibração e validação dos modelos PLSR foram feitos com o Software Unscrambler® X (CAMO software AS, Oslo, Norway).

## Resultados

### *Normalidade dos dados*

Figura 27 - Probabilidade de normalidade dos dados de concentração de nitrogênio foliar: (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016; (E) estádio R1 e (E) estádio R3 2016

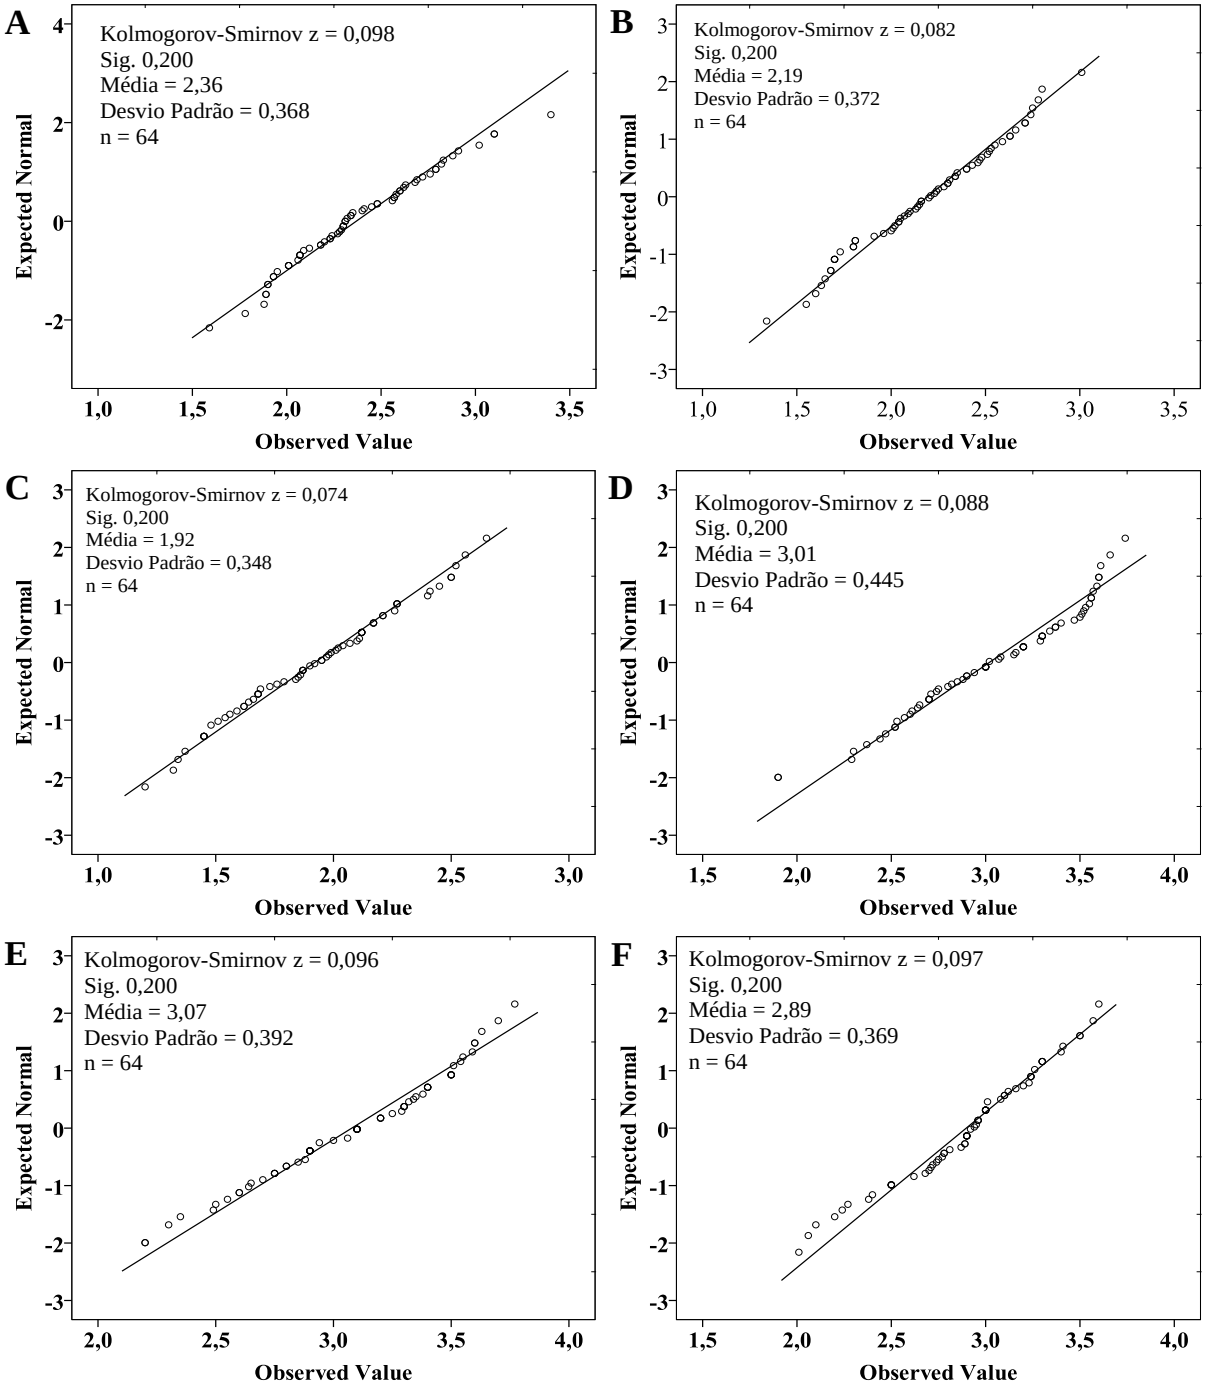


Fonte: elaboração do autor.

O teste de Kolmogorov-Smirnov aplicado aos conjuntos de dados de nitrogênio foliar para as três épocas de avaliação nos dois ciclos da cultura, indicou a distribuição normal dos dados (*p*-value = 0,20) (FIGURA 27). Dessa forma, os modelos foram desenvolvidos utilizando os dados de concentração de N foliar expressos em porcentagem (%).

***Variações na concentração de N foliar***

A concentração média de N na folha variou de 1,37 a 2,90% em 2015 (FIGURA 28) e 2,52 a 3,43% em 2016 (FIGURA 29), dependendo do tratamento. Os valores mais altos no segundo ciclo podem ter sido influenciados por efeitos residuais de N no solo, provenientes do ciclo anterior.

Figura 28 - Concentração de N foliar (%) em função dos tratamentos em 2015 (Ciclo I). As barras indicam o erro padrão da média (n =4)

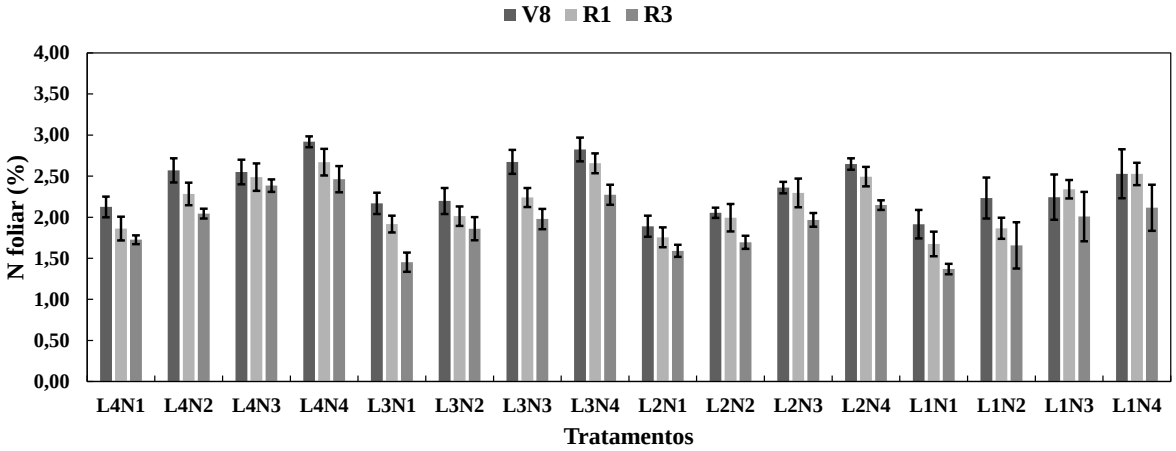


Fonte: elaboração do autor.

A concentração de N foliar aumentou conforme as taxas de aplicação de N dos dois ciclos. Em 2015 foi evidenciada diminuição acentuada do N foliar de 0,25% (2,5 g/kg) entre os ciclos V8 e R1 e posteriormente de 0,21% (2,1 g/kg) em R3. Em 2016, o decréscimo no N foliar foi menos acentuado entre o estádio V8 e R1 com 0,05% (0,5 g/kg) e maior entre R1 e R3 com 0,22 (2,2 g/kg). A diminuição da concentração média foliar de N observada ocorre pelo efeito da diluição do elemento nas folhas no sentido da progressão do estágio vegetativo para os estádios reprodutivos (R1 e R3).

Figura 29 - Concentração de N foliar (%) em função dos tratamentos em 2016 (Ciclo II). As barras indicam o erro padrão da média (n =4)

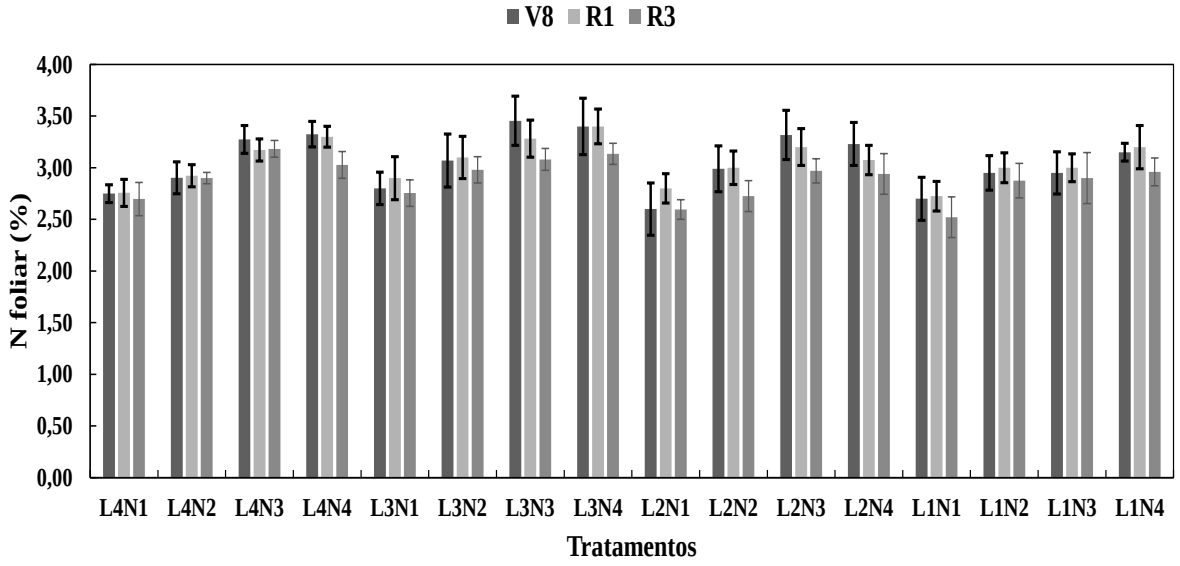


Fonte: elaboração do autor.

***Regressão entre a reflectância de bandas individuais e a concentração de N foliar***

*Dados de laboratório*

Os valores de coeficiente de correlação de Pearson entre a concentração de N foliar e os valores de reflectância para os dados de laboratório são mostrados na Figura 30.

As maiores correlações foram observadas na região do visível (400 nm a 720 nm), ocorrendo de forma negativa, e tenderam a diminuir na região do infravermelho próximo e médio.

As bandas de absorção que apresentaram a relação mais forte entre reflectância e o N foliar variaram conforme a época de avaliação. Para a os dados coletados aos 75 dias (estádio R3) no primeiro ciclo, a melhor banda está centrada em 689 nm (r = -0,738). No segundo ciclo, as melhores correlações foram encontradas para as bandas 699 nm (r = -0,723), 653 nm (r = -0,722) e 718 nm (r = -0,737) aos 35 dias (estádio V8), 55 (estádio R1) e 75 dias (estádio R3), respectivamente.

Os modelos de regressão preditivos entre bandas individuais e a concentração de N foliar e suas respectivas validações são mostrados nas Figuras 31 e 32.

Figura 30 - Correlação de Pearson (r) entre a concentração de N foliar e reflectância da folha para todas as bandas entre 350 nm e 2500 nm em condições de laboratório. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016

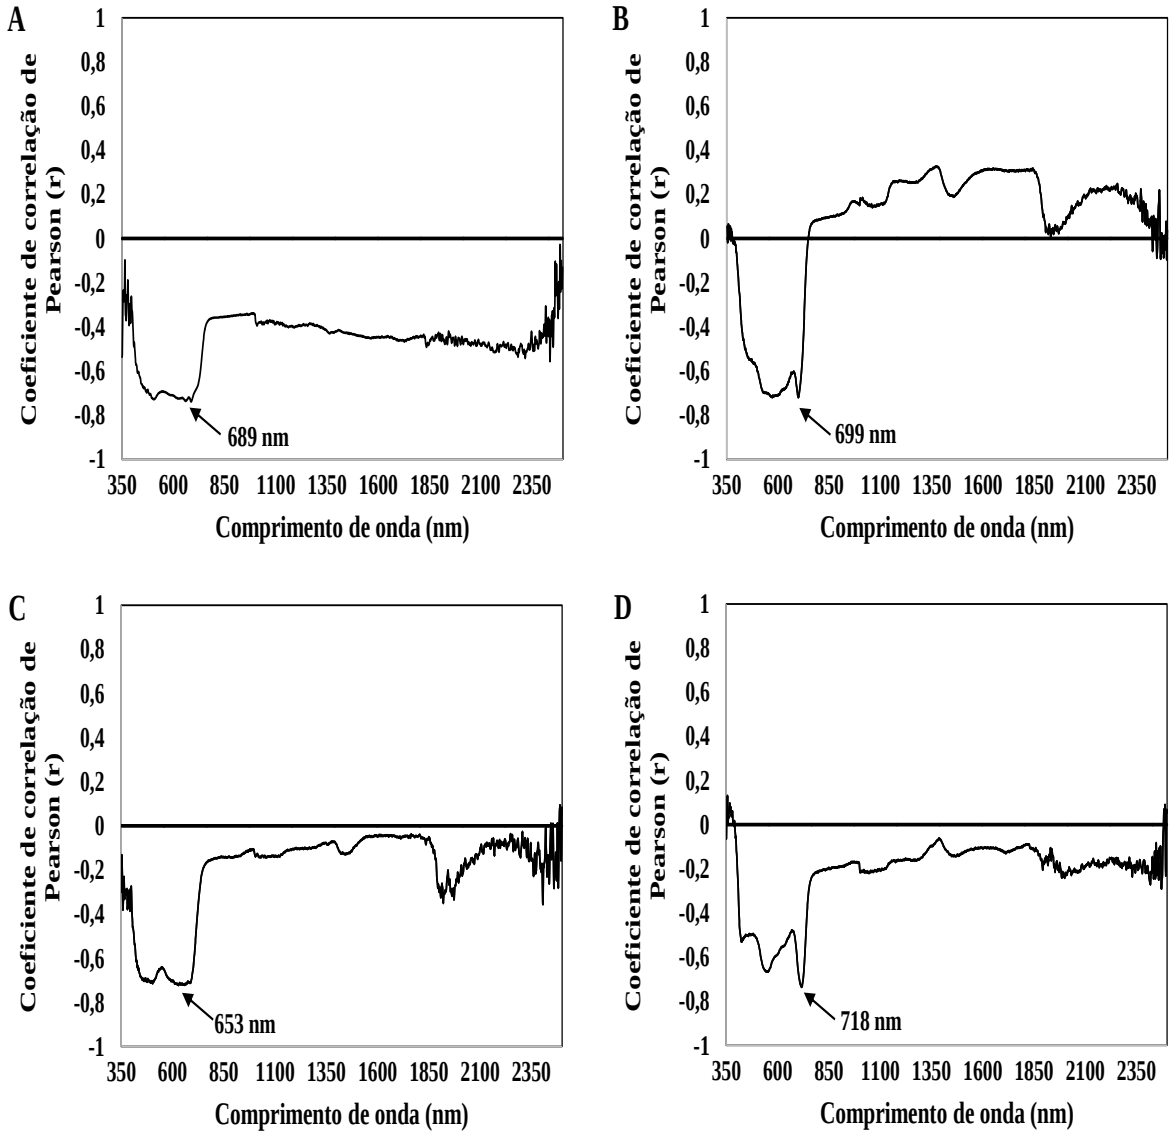


Fonte: elaboração do autor.

Figura 31 - Equações de calibração obtidas a partir da relação entre reflectância de bandas individuais e a concentração de N foliar. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016

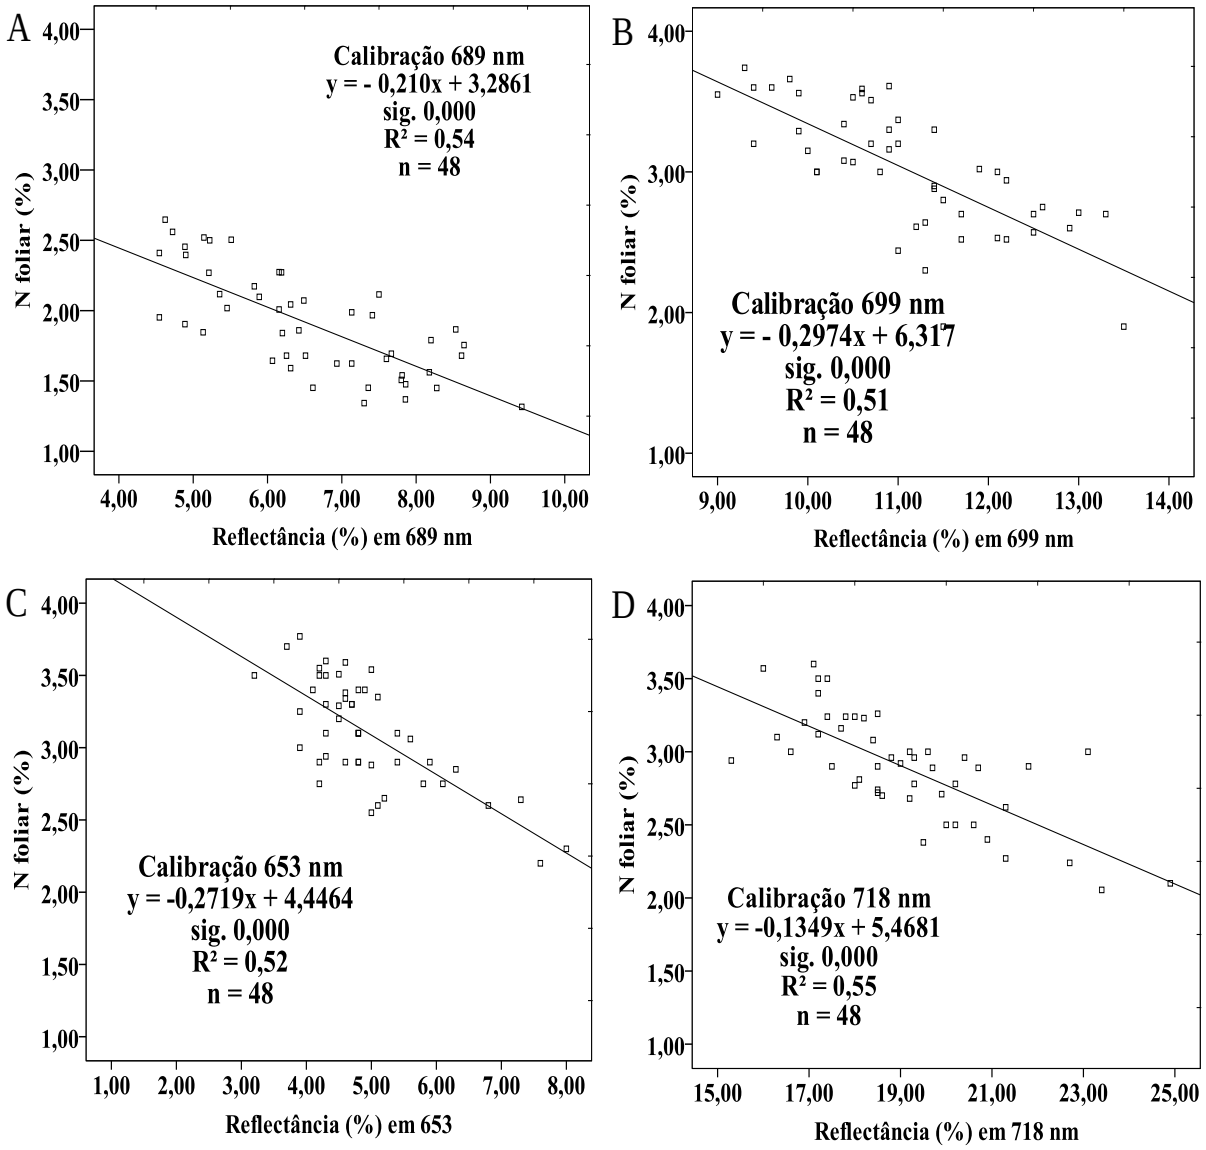


Fonte: elaboração do autor.

Para os dados do ciclo I, no estádio R3, a banda posicionada em 689 nm permitiu o ajuste de um modelo linear com capacidade de acerto $R^2$ = 0,82 e RMSE = 0,34. Os conjuntos de dados do ciclo II apresentaram menores valores de $R^2$, porém proporcionaram menor erro na predição. Os modelos para os estádios V8 e R3 resultaram em um melhor desempenho ($R^2$ =0,79 e 0,68 e RMSE = 0,23 e 0,24, respectivamente) em relação ao modelo R1 ($R^2$ = 0,56 e RMSE = 0,30).

Figura 32 - Equações de validação obtidas a partir da relação entre reflectância de bandas individuais e a concentração de N foliar. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016

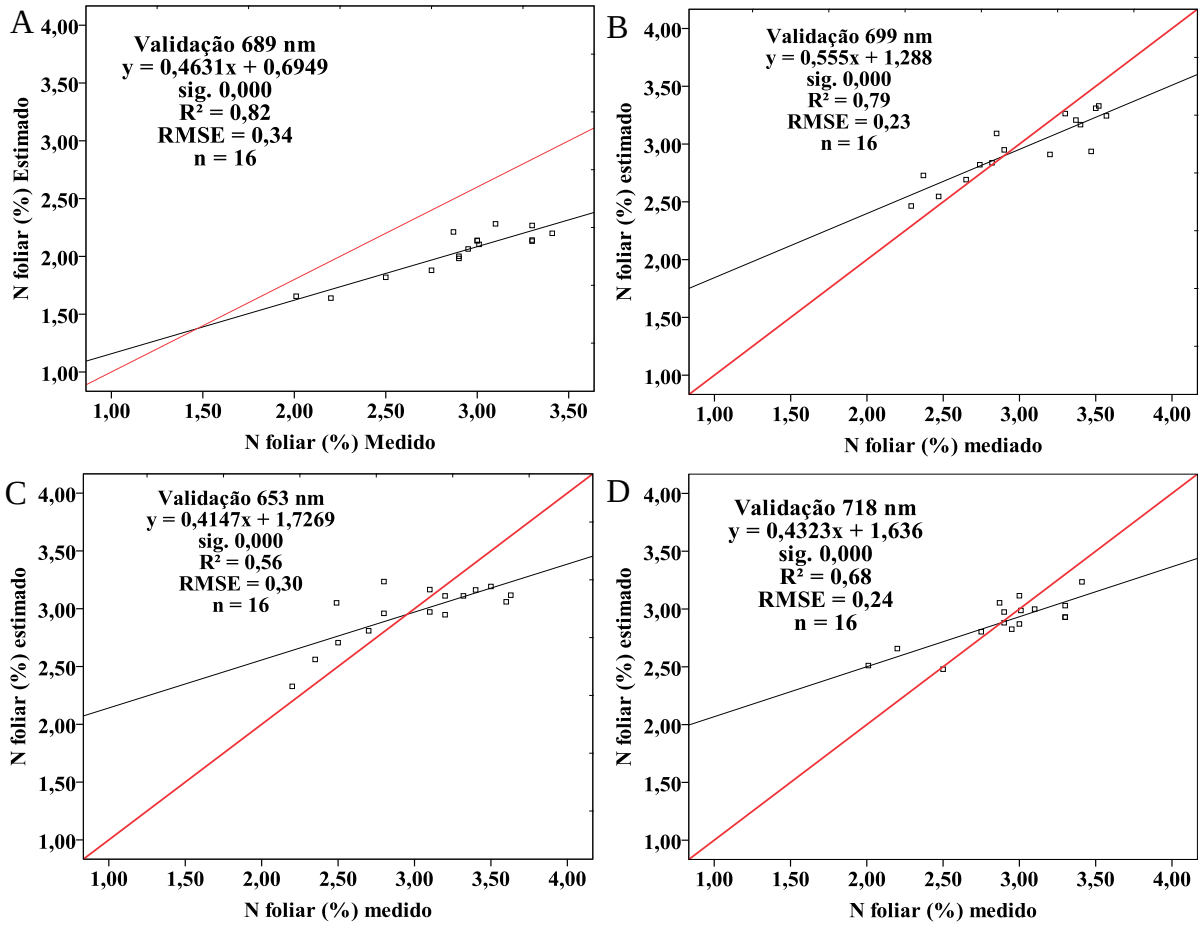


Fonte: elaboração do autor.

*Dados de campo*

Os valores de coeficiente de correlação de Pearson entre a concentração de N foliar e os valores de reflectância para os dados de campo, coletados em nível de dossel, são mostrados na Figura 33.

As maiores correlações foram observadas na região do visível e no infravermelho próximo. No visível verificaram-se maiores correlações negativas na região do vermelho, na faixa entre 650 nm e 700 nm, aumentando positivamente na região do infravermelho próximo partir dessa faixa. Ambas as regiões apresentaram importância para seleção de bandas relacionadas à concentração de N foliar. No primeiro ciclo, as melhores bandas estão centradas em 676 nm (r = -0,668), 669 nm (r = -0,597) e 677 (r = - 0,715) para os estádios V8, R1 e R3, respectivamente. Para o segundo ciclo, as melhores correlações estão nas bandas 673

nm (r = -0,573) e 684 nm (r = -0,739) nos estádios V8 e R3, respectivamente. Na região do infravermelho próximo, foi verificado alta correlação (r > 0,55) no estádio V8 nas bandas 760 nm (r = 0,662) e 776 (r = 0,563) para os ciclos I e II, respectivamente.

Figura 33 - Correlação de Pearson (r) entre a concentração de N foliar e reflectância da folha para dados coletado em condições de campo. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016

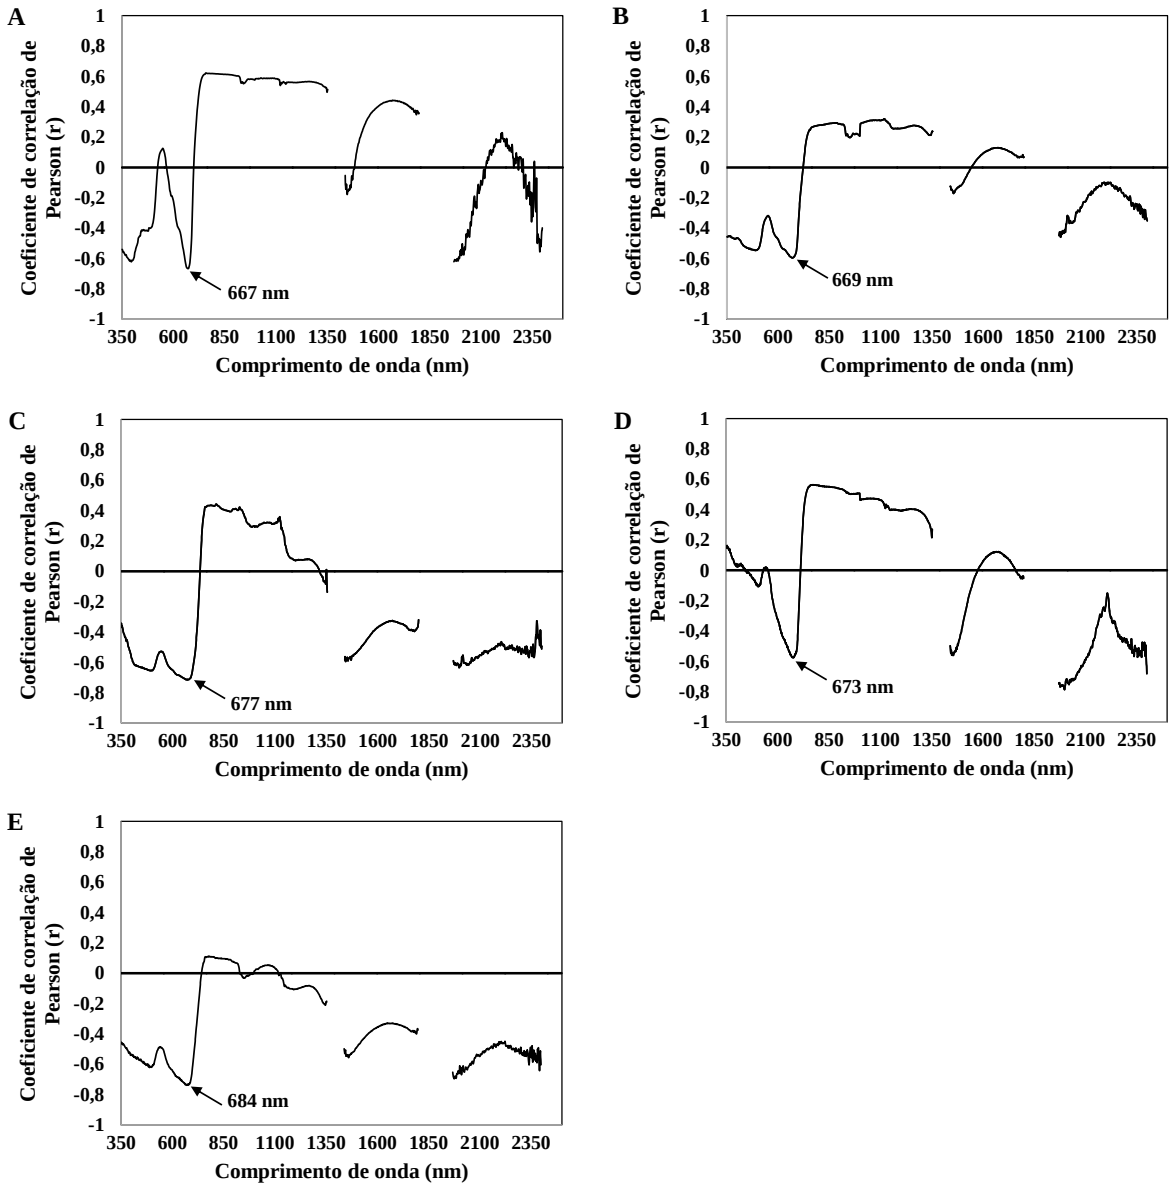


Fonte: elaboração do autor.

Os modelos de regressão preditivos entre bandas individuais e N foliar (%) e suas respectivas validações para dados coletados em campo são mostrados nas Figuras 34 e 35.

Figura 34 - Equações de calibração obtidas a partir da relação entre reflectância de bandas individuais e a concentração de N foliar. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016

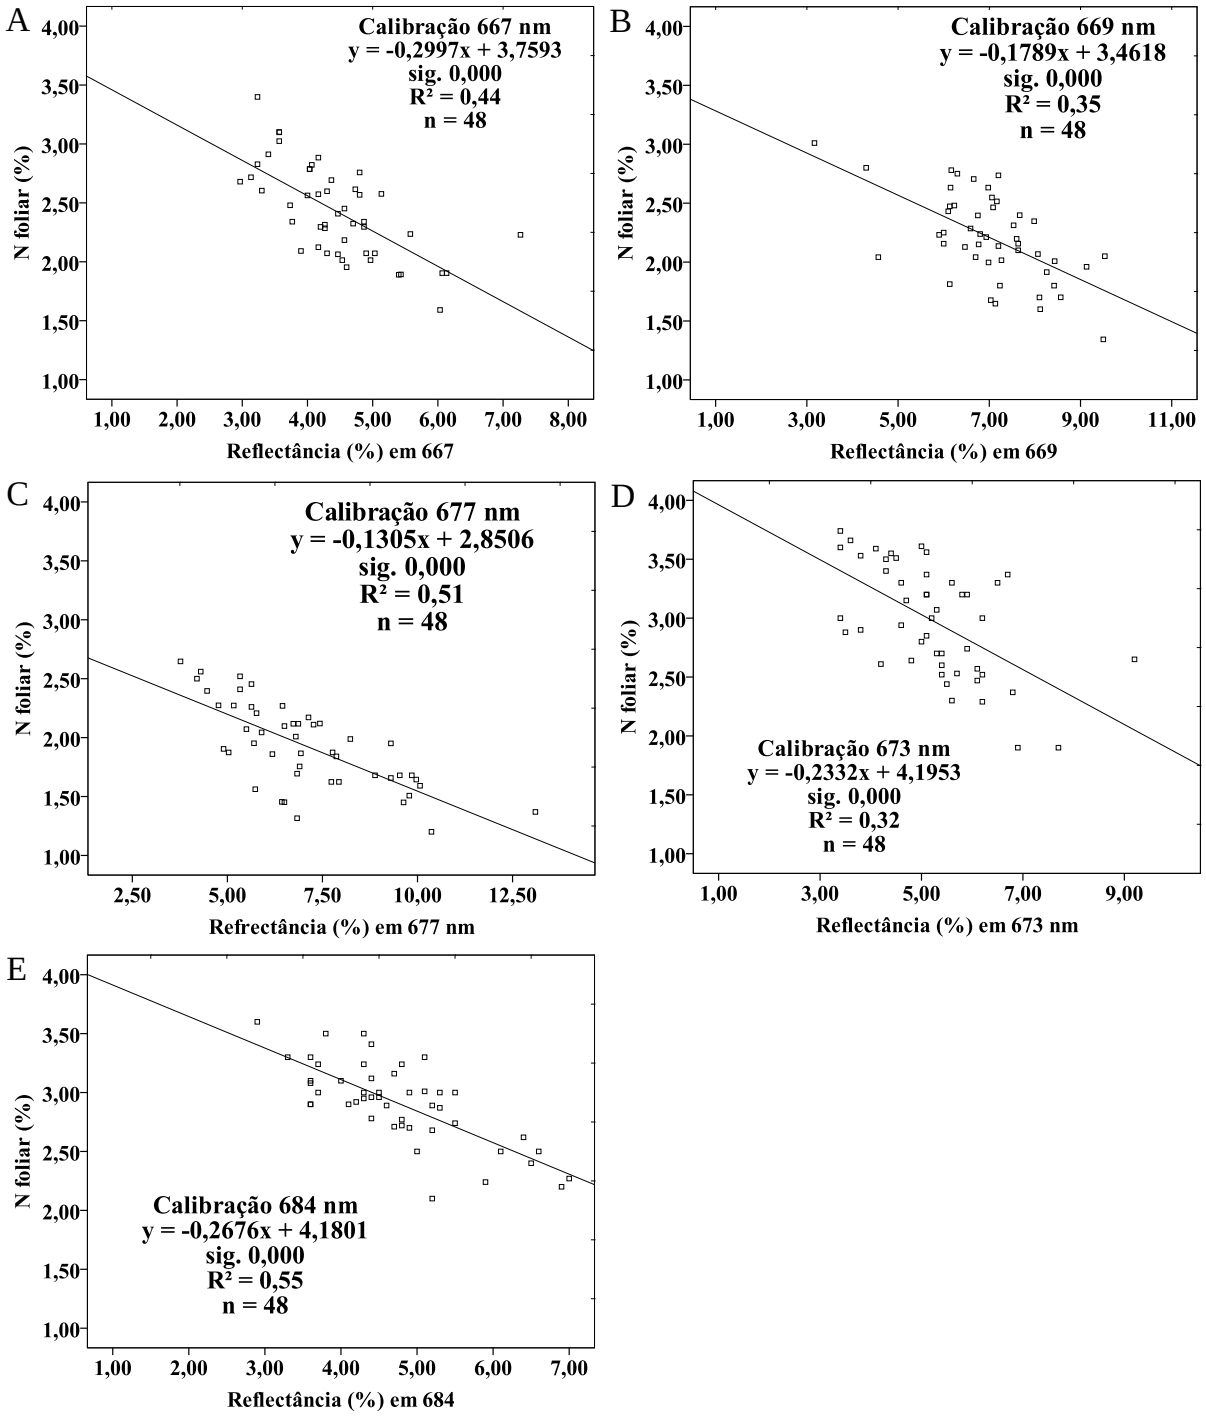


Fonte: elaboração do autor.

Figura 35 - Equações de validação obtidas a partir da relação entre reflectância de bandas individuais e a concentração de N foliar. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016

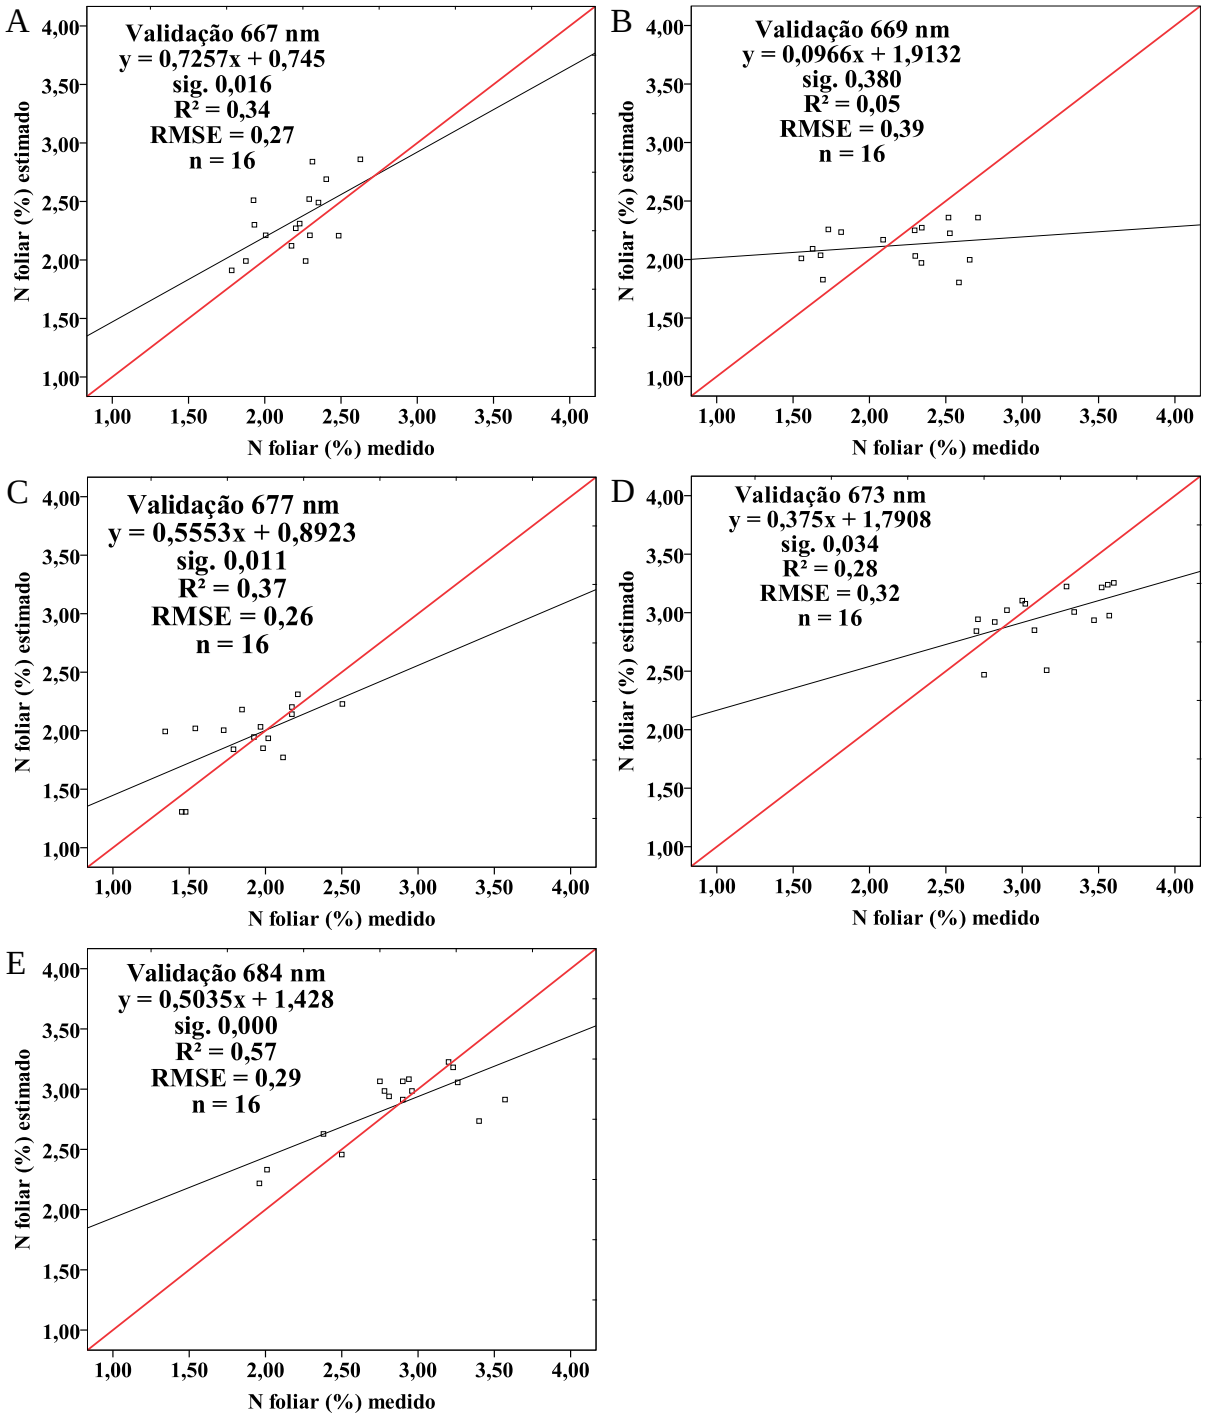


Fonte: elaboração do autor.

Em geral, os modelos de campo apresentaram desempenho inferior em relação aos obtidos em condições de laboratório. Para os dados do ciclo I, as bandas posicionadas em 667 nm, 669 nm e 677 nm alcançaram baixa capacidade de acerto para os modelos lineares dos

estádios V8 ($R^2$ = 0,34 e RMSE = 0,37), R1 ($R^2$ = 0,05 e RMSE = 0,39) e R3 ($R^2$ = 0,37 e RMSE = 0,26), respectivamente. No ciclo II, as bandas centradas em 673 nm e 684 nm permitiram o melhor ajuste para os estádios V8 ($R^2$ = 0,28 e RMSE = 0,32) e R3 ($R^2$ = 0,57 e RMSE = 0,29).

***Normalized Difference Spectral Index – NDSI***

*Dados de laboratório*

Na Figura 36 foram plotados os contornos de $R^2$ obtidos das regressões lineares para o NDNI em função do N foliar para os conjuntos amostrais de calibração obtidos em laboratório nas diferentes épocas de avaliação.

O posicionamento das bandas que compuseram o melhor índice normalizado variou conforme o estádio fenológico. No ciclo I a razão normalizada mais promissora foi encontrada entre 505 nm (banda i) e 922 nm (banda j) para o estádio R3, alcançando coeficiente de determinação de 0,57. Para os dados do ciclo II, as melhores bandas foram 529 nm (banda i) e 1182 nm (banda j), 690 nm (banda i) e 910 nm (banda j) e 733 nm (banda i) e 738 nm (banda j), com coeficiente de determinação de 0,71, 0,75 e 0,56 para os estádios V8, R1 e R3, respectivamente.

Os modelos de regressão preditivos entre NDNI e a concentração de N foliar e suas respectivas validações são apresentados nas Figuras 37 e 38.

Verificou-se que a capacidade de predição do NDNI com bandas 690 nm e 910 nm ($R^2$ = 0,80 e RMSE = 0,20), para o estádio R1 no ciclo II, foi superior aos demais NDNI calculados para as demais épocas de avaliação. Apenas nesse estádio, o NDNI foi superior aos modelos de bandas individuais. O menor desempenho para o NDNI foi obtido para o estádio R3 no ciclo I ($R^2$ = 0,59 e RMSE = 0,21).

Figura 36 - Coeficiente de determinação entre todas as combinações de reflectância de bandas i e j usadas para obter NDNI e concentração de N foliar para o conjunto amostral de calibração de laboratório. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016

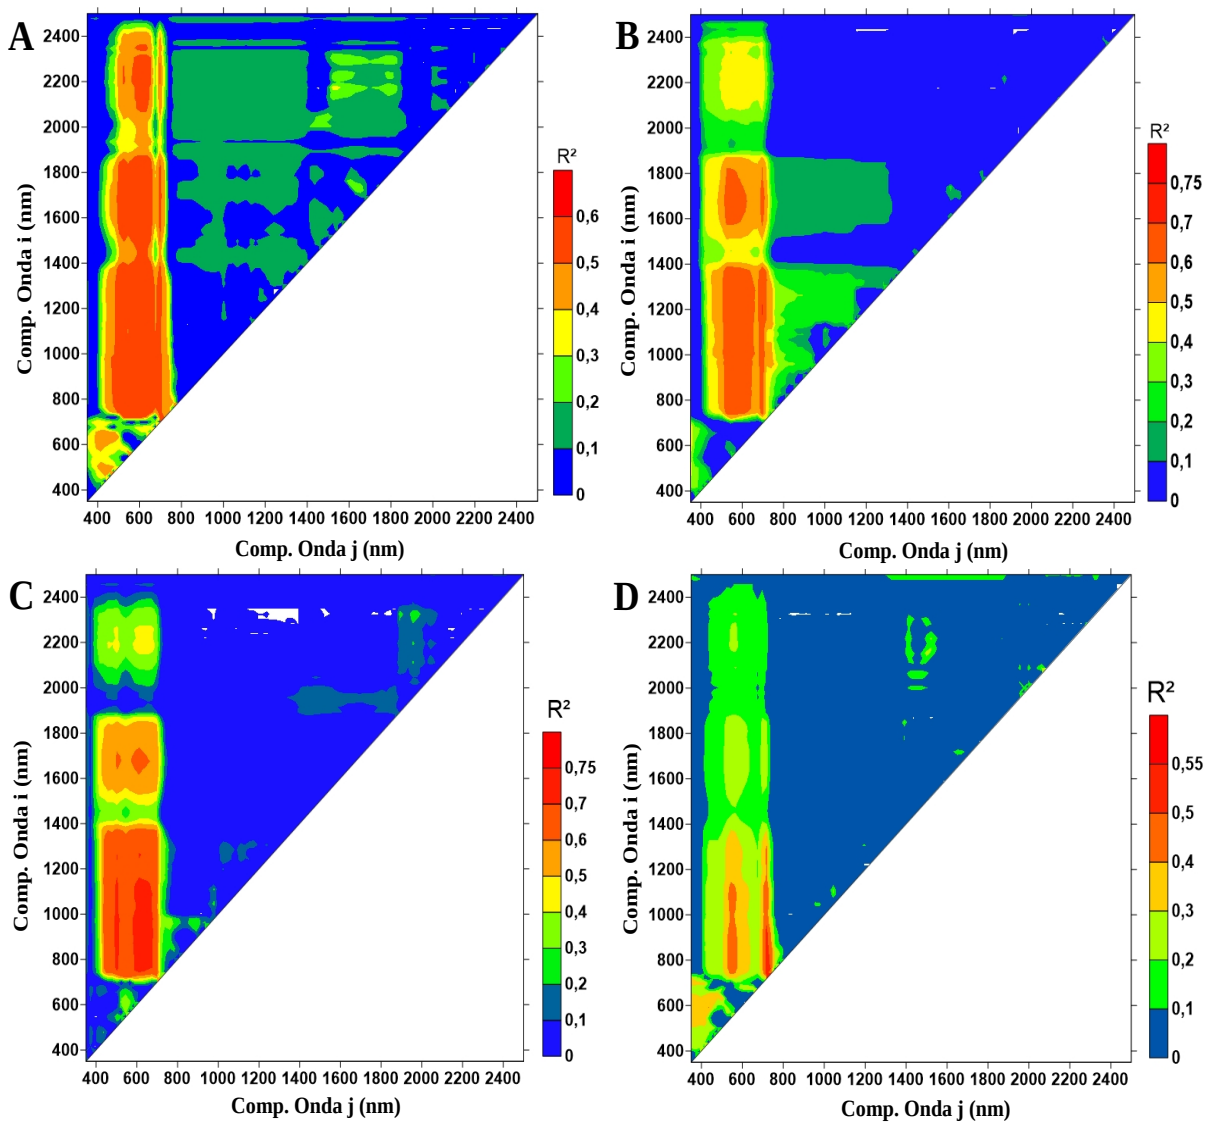


Fonte: elaboração do autor,

Figura 37 - Equações de calibração entre o melhor NDNI e a concentração de N foliar. (A) estádio R3 2015 ([922-505]/[922+505]); (B) estádio V8 2016 ([1182-529]/[1182+529]); (C) estádio R1 2016 ([910-690]/[910+690]) e (D) estádio R3 2016 ([738-733]/[738+733])

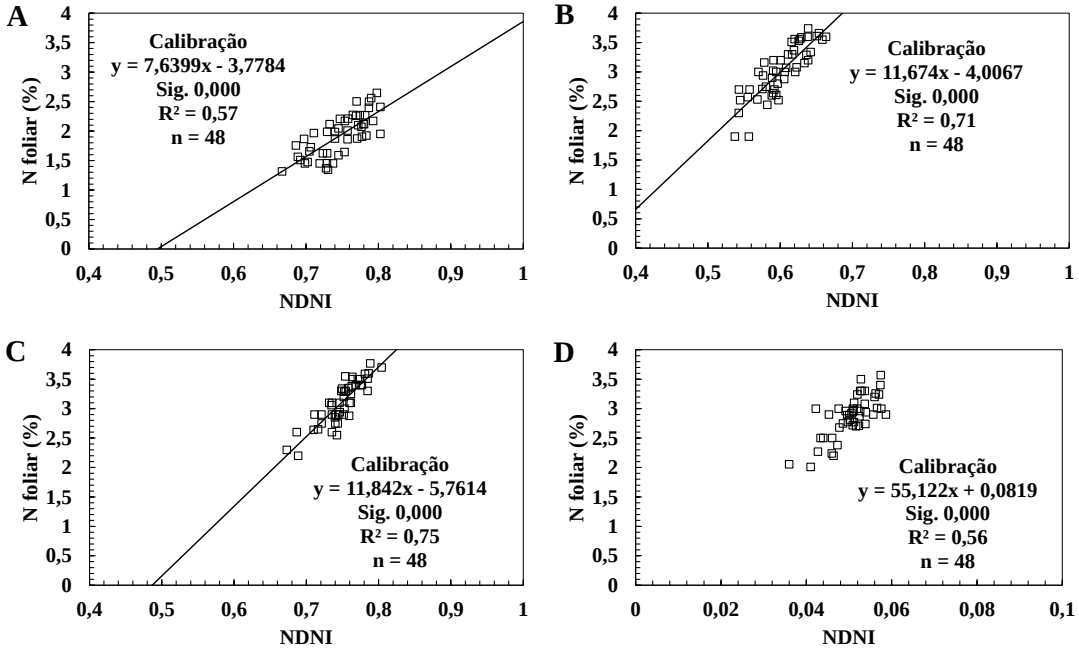


Fonte: elaboração do autor.

Figura 38 -. Equações de validação entre o melhor NDNI e a concentração de N foliar. (A) estádio R3 2015 ([922-505]/[922+505]); (B) estádio V8 2016 ([1182-529]/[1182+529]); (C) estádio R1 2016 ([910-690]/[910+690]) e (D) estádio R3 2016 ([738-733]/[738+733])

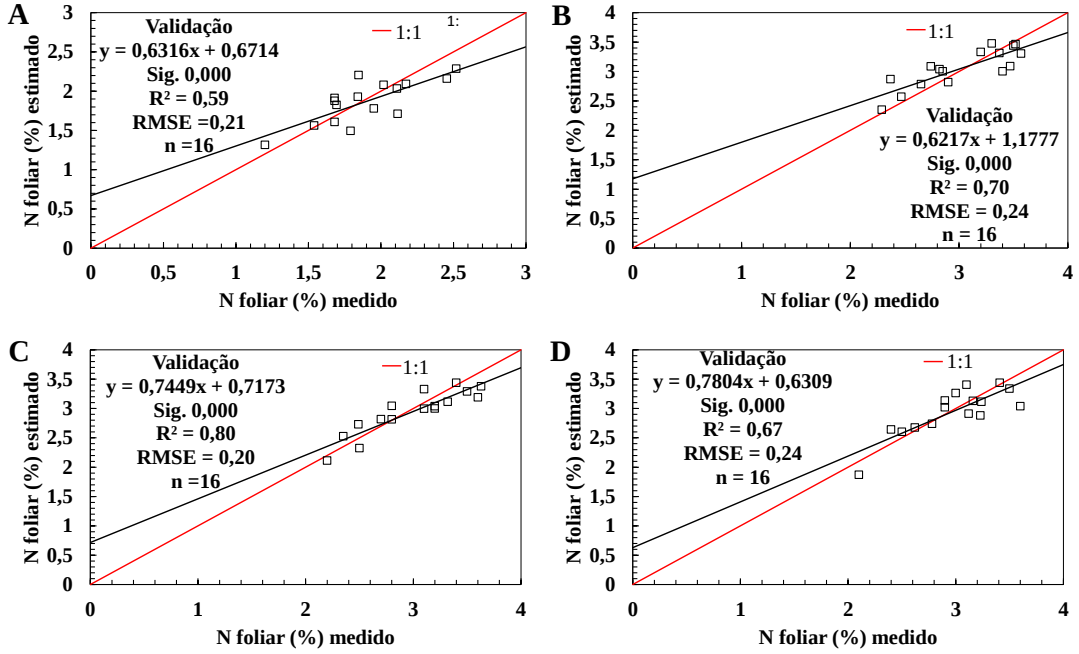


Fonte: elaboração do autor.

*Dados de campo*

Na Figura 39 foram plotados os contornos de $R^2$ obtidos das regressões lineares para o NDNI em função do N foliar para os conjuntos de dados de calibração obtidos em campo na faixa entre 350 nm a 1300 nm, para as diferentes fases fenológicas. Assim como nos dados de laboratório, verificou-se uma variabilidade nos posicionamentos das melhores bandas para o índice normalizado.

Para os dados do ciclo I, a melhor razão normalizada encontrada para o estádio V8, está posicionada entre 622 nm (banda i) e 722 nm (banda j), apresentando coeficiente de determinação de 0,79. Esse modelo obteve melhor desempenho em relação aos melhores índices obtidos para os estádios R1 ($R^2$ = 0,78) e R3 ($R^2$ = 0,62). No ciclo II, o NDNI obtido para o estádio para o estádio V8 também apresentou melhor desempenho em relação ao R3. No modelo V8 a razão normalizada mais promissora foi entre 702 nm (banda i) e 720 nm (banda j) apresentando coeficiente de determinação de 0,80. Para o modelo R3 os melhores posicionamentos foram 684 nm (banda i) e 762 nm (banda j) com coeficiente de determinação de 0,75.

Os modelos de regressão preditivos entre NDNI e a concentração de N foliar e suas respectivas validações para os conjuntos de dados obtidos em campo são mostrados nas Figuras 40 e 41.

Constatou-se que a capacidade de predição do NDNI com bandas 684 nm e 726 nm ($R^2$ = 0,78 e RMSE = 0,20), para o estádio R3 no ciclo II, foi melhor em relação aos outros NDNIs calculados. Para o estádio V8, a capacidade de previsão usando as bandas 702 nm e 720 nm no ciclco II ($R^2$ = 0,67 e RMSE = 0,21) foi superior ao encontrado no ciclo I utilizando as bandas 622 nm e 722 nm ($R^2$ = 0,55 e RMSE = 0,21). Para o estádio R1 no ciclo I, as bandas 646 nm e 933 nm atingiram valores medianos em relação às demais épocas ($R^2$ = 0,68 e RMSE = 0,25).

Todos os índices normalizados desenvolvidos para condições de campo foram melhor ajustados que as equações de regressão para as bandas individuais. Desse modo, para essas condições de obtenção de dados, os NDNIs apresentam maior perspectiva de sucesso em aplicações de dados hiperespectrais para predições de N foliar no milho.

Figura 39 - Coeficiente de determinação entre todas as combinações de reflectância de bandas i e j usadas para obter NDNI e concentração de N foliar para o conjunto amostral de calibração de campo. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016

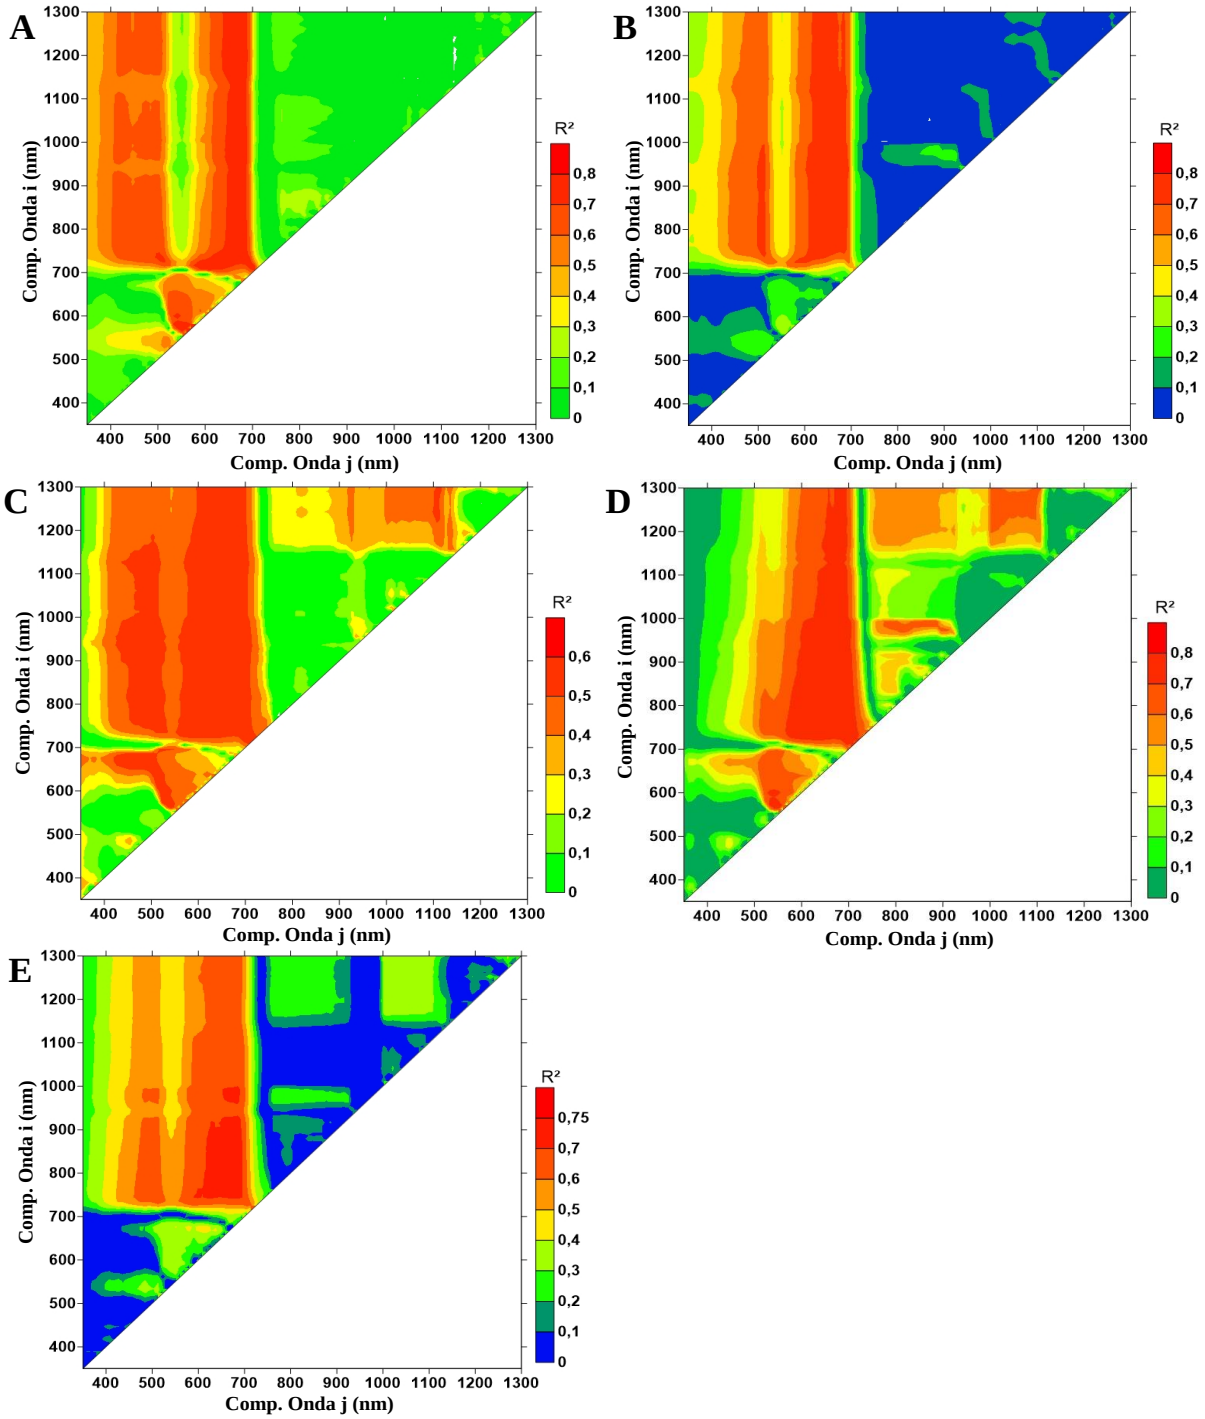


Fonte: elaboração do autor.

Figura 40 - Equações de calibração entre o melhor NDNI e a concentração de N foliar para dados de campo. (A) estádio V8 2015 ([722-622]/[722+622]); (B) estádio R1 2015 ([933-646]/[933+646]); (C) estádio R3 2015 ([716-715]/[716+715]); (D) estádio V8 2016 ([720-702]/[720+702]) e (E) estádio R3 2016 ([762-684]/[762+684])

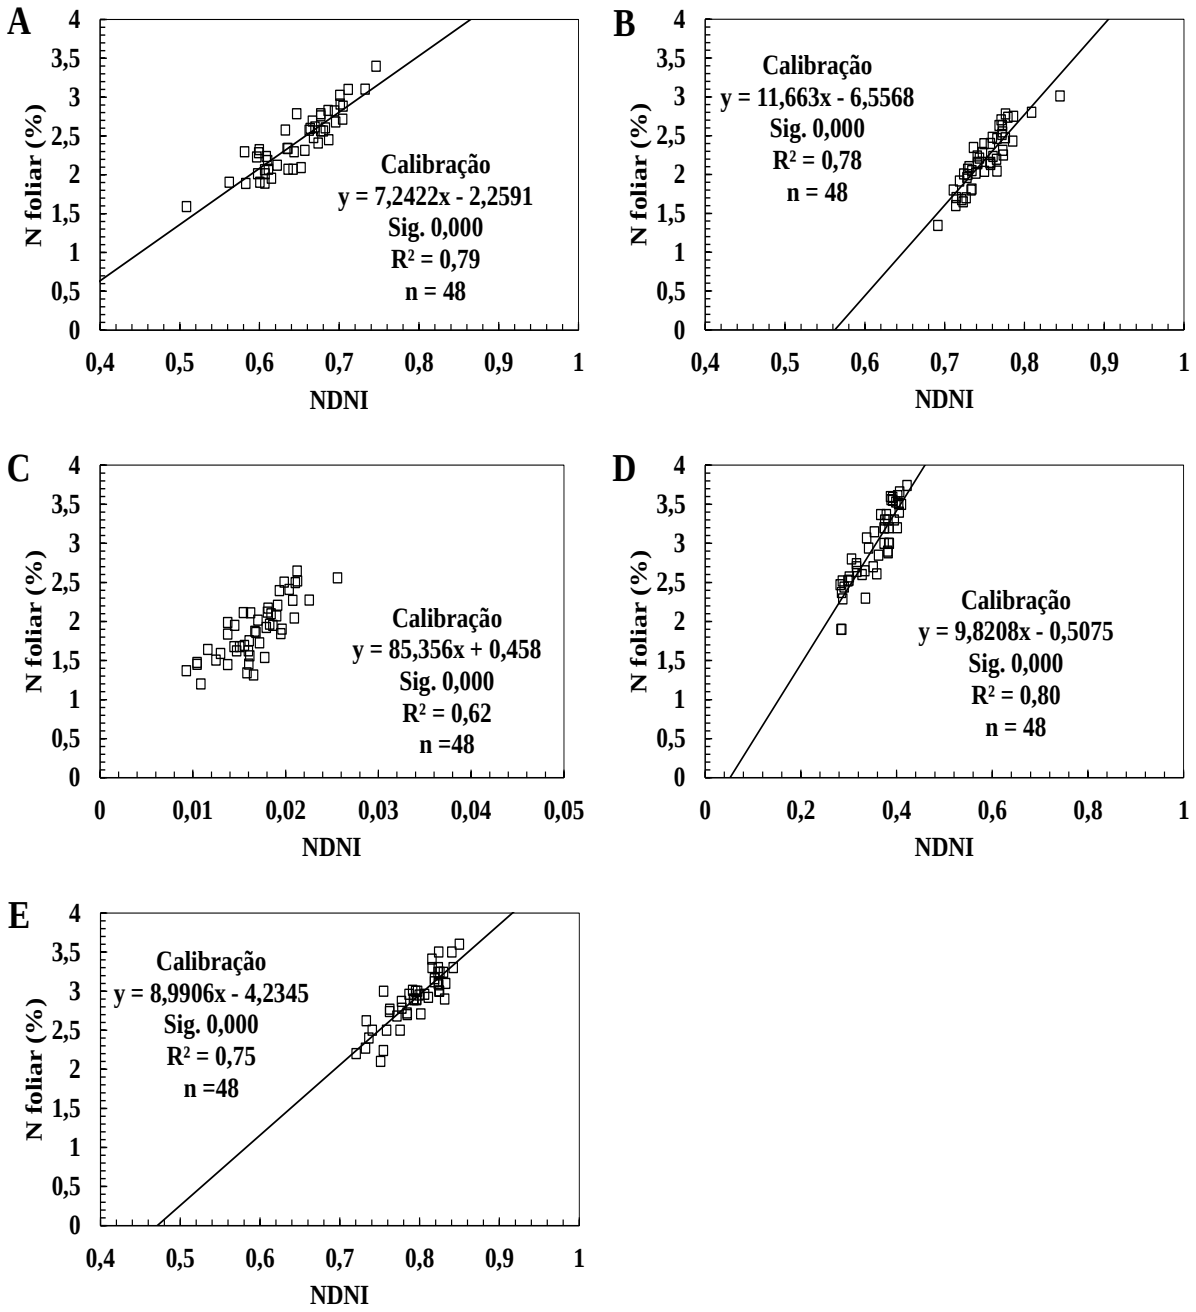


Fonte: elaboração do autor.

Figura 41 - Equações de validação entre o melhor NDNI e a concentração de N foliar para dados de campo. (A) estádio V8 2015 ([722-622]/[722+622]); (B) estádio R1 2015 ([933-646]/[933+646]); (C) estádio R3 2015 ([716-715]/[716+715]); (D) estádio V8 2016 ([720-702]/[720+702]) e (E) estádio R3 2016 ([762-684]/[762+684])

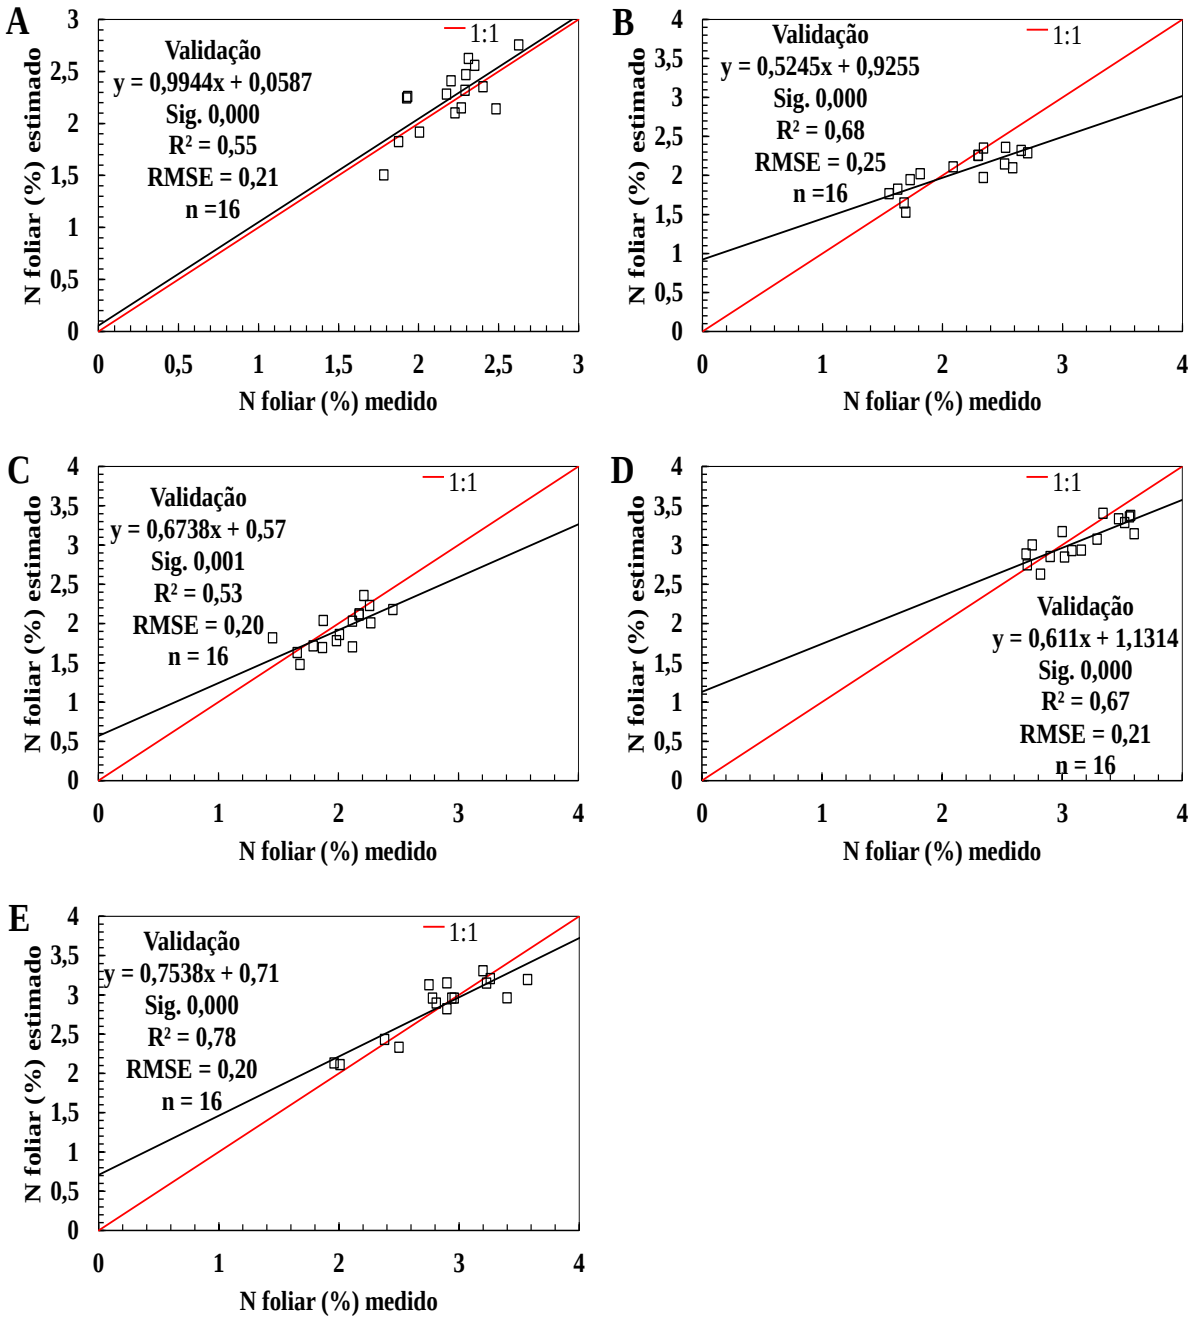


Fonte: elaboração do autor.

***Partial Least Squares Regression – PLSR***

*Dados de laboratório*

A partir dos conjuntos de dados amostrais de calibração e validação, os modelos PLSR foram desenvolvidos para cada estádio fenológico da cultura. Para os dados de laboratório foram utilizadas todas as bandas da faixa entre 350 nm e 2500 nm como preditores (X). Na Tabela 11 encontram-se as estatísticas descritivas dos modelos gerados. Foi verificado que o modelo R1 2016 (ciclo II) obteve desempenho superior aos demais, produzindo o menor erro da validação cruzada (RMSECV = 0,198 e $R^2$cv = 0,732), utilizando quatro fatores que explicam 93,89% da variância acumulada (TABELA 11 e FIGURA 42).

Tabela 11 - Estatísticas descritivas da calibração dos modelos PLSR (n =48) e validação (n =16) para conjunto de dados obtidos em laboratório

| Modelo | Nº Fatores | Variância em X (%) | $R^2$ Calib. | $R^2$ Valid. Cruzada | RMSECV | $R^2$ Pred. | RMSEP |
|---|---|---|---|---|---|---|---|
| R3 2015 | 3 | 94,45 | 0,565 | 0,482 | 0,254 | 0,636 | 0,223 |
| V8 2016 | 4 | 95,24 | 0,770 | 0,681 | 0,232 | 0,767 | 0,357 |
| R1 2016 | 4 | 93,89 | 0,809 | 0,737 | 0,198 | 0,824 | 0,190 |
| R3 2016 | 4 | 94,49 | 0,698 | 0,502 | 0,271 | 0,564 | 0,217 |

$R^2$ = coeficiente de determinação; RMSECV = erro médio quadrático da validação cruzada; RMSEP = erro médio quadrático da predição. Fonte: elaboração do autor.

A validação com conjunto de dados independente é mostrada na Tabela 11. Como pode ser observado, o modelo R1 2016 obteve melhor desempenho na predição atingindo $R^2$ = 0,824 e RMSEP= 0,190 (TABELA 11 E FIGURA 43).

Para os dados de laboratório, o modelo preditivo PLSR R1 2016 obteve melhor desempenho do que os modelos com banda individual e índice normalizado, para esse mesmo estádio fenológico. Para os demais estádios, os modelos com bandas individuais apresentaram melhor resultado.

Em geral, as melhores determinações ocorreram nos estádios V8 e R1 para todas as metodologias utilizadas, exceto para R1 2016 utilizando banda individual ($R^2$ = 0,56 e RMSE = 0,30). Em contrapartida, no estádio R3, com exceção do modelo R3 2015 de banda individual, obtiveram coeficientes de determinação abaixo de 0,70.

Figura 42 - Resultados da calibração e validação cruzada dos modelos PLSR. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016

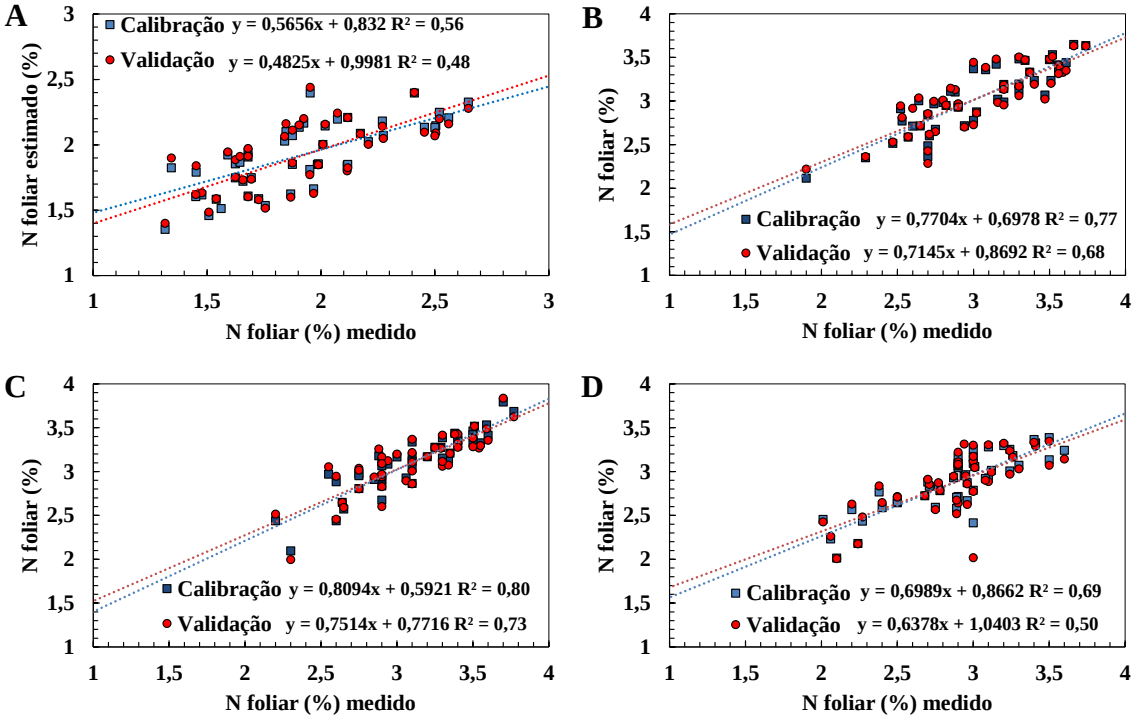


Fonte: elaboração do autor.

Figura 43 - Equações de validação entre os modelos PLSR e a concentração de N foliar para dados de laboratório. (A) estádio R3 2015; (B) estádio V8 2016; (C) estádio R1 2016 e (D) estádio R3 2016

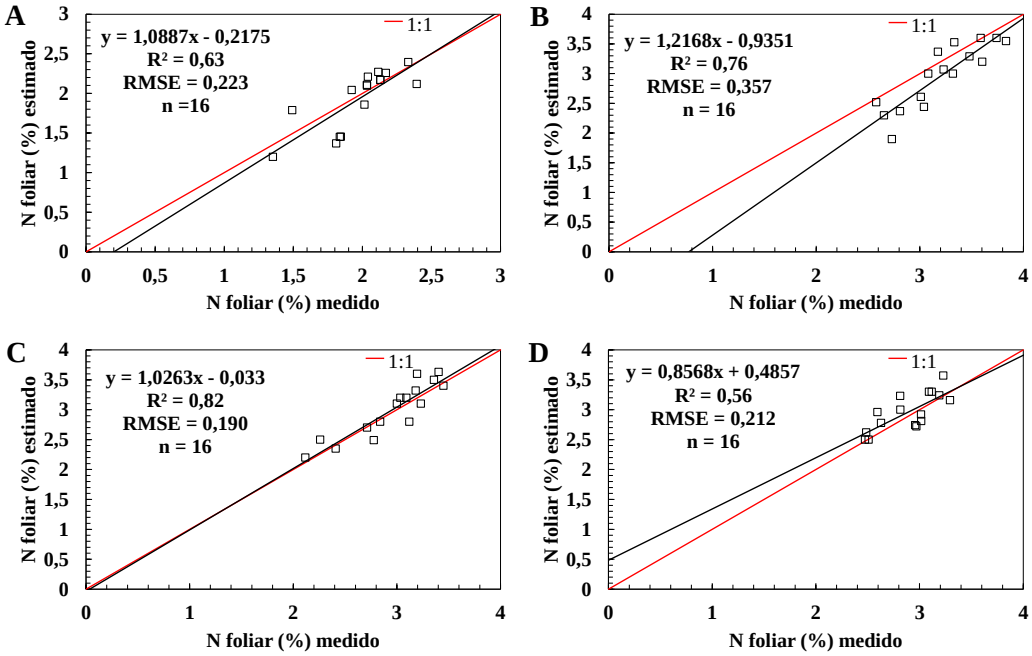


Fonte: elaboração do autor.

*Dados de campo*

Para os dados obtidos em campo foram utilizadas todas as bandas da faixa entre 350 nm e 1300 nm como preditores (X).

Na Tabela 12 encontram-se as estatísticas descritivas dos modelos gerados. Foi verificado que o modelo R1 2015 (ciclo I) obteve melhor desempenho em relação aos demais. Esse modelo obteve o menor erro da validação cruzada (RMSECV = 0,145 e $R^2cv$ = 0,837), utilizando quatro fatores que explicam juntos 98,88% da variância acumulada (TABELA 12 E FIGURA 44).

Tabela 12 - Estatísticas descritivas da calibração dos modelos PLSR (n =48) e validação (n =16) para conjunto de dados obtidos em campo

| Modelo | Nº Fatores | Variância em X (%) | $R^2$ Calib. | $R^2$ Valid. Cruzada | RMSECV | $R^2$ Pred. | RMSEP |
|---|---|---|---|---|---|---|---|
| V8 2015 | 4 | 96,97 | 0,819 | 0,766 | 0,176 | 0,687 | 0,229 |
| R1 2015 | 4 | 98,88 | 0,862 | 0,837 | 0,145 | 0,773 | 0,224 |
| R3 2015 | 6 | 98,42 | 0,660 | 0,501 | 0,250 | 0,470 | 0,248 |
| V8 2016 | 3 | 97,75 | 0,813 | 0,773 | 0,222 | 0,692 | 0,199 |
| R3 2016 | 4 | 97,90 | 0,799 | 0,718 | 0,1828 | 0,701 | 0,226 |

$R^2$ = coeficiente de determinação; RMSECV = erro médio quadrático da validação cruzada; RMSEP = erro médio quadrático da predição. Fonte: elaboração do autor.

A validação com conjunto de dados independente é mostrada na Tabela 12. Pode-se verificar que o modelo R1 2015 produziu melhor ajuste da modelo na predição atingindo $R^2$ = 0,773 e RMSEP= 0,224, porém o menor erro médio quadrático foi observado no modelo V8 2016 (RMSE = 0,199) (TABELA 12 E FIGURA 45).

Para os dados de campo, o modelo preditivo PLSR para os estádios R1 e V8, para ambos os ciclos de cultivos, apresentaram melhor desempenho em relação aos modelos de bandas individuais e índices normalizados. No entanto, para os dados coletados no estádio R3 observaram-se melhores resultados para os índices normalizados de nitrogênio.

Os modelos de bandas individuais para esse nível de coleta de dados espectrais apresentaram resultados inferiores em relação às outras estratégias de modelagem.

Figura 44 - Resultados da calibração e validação cruzada dos modelos PLSR. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016

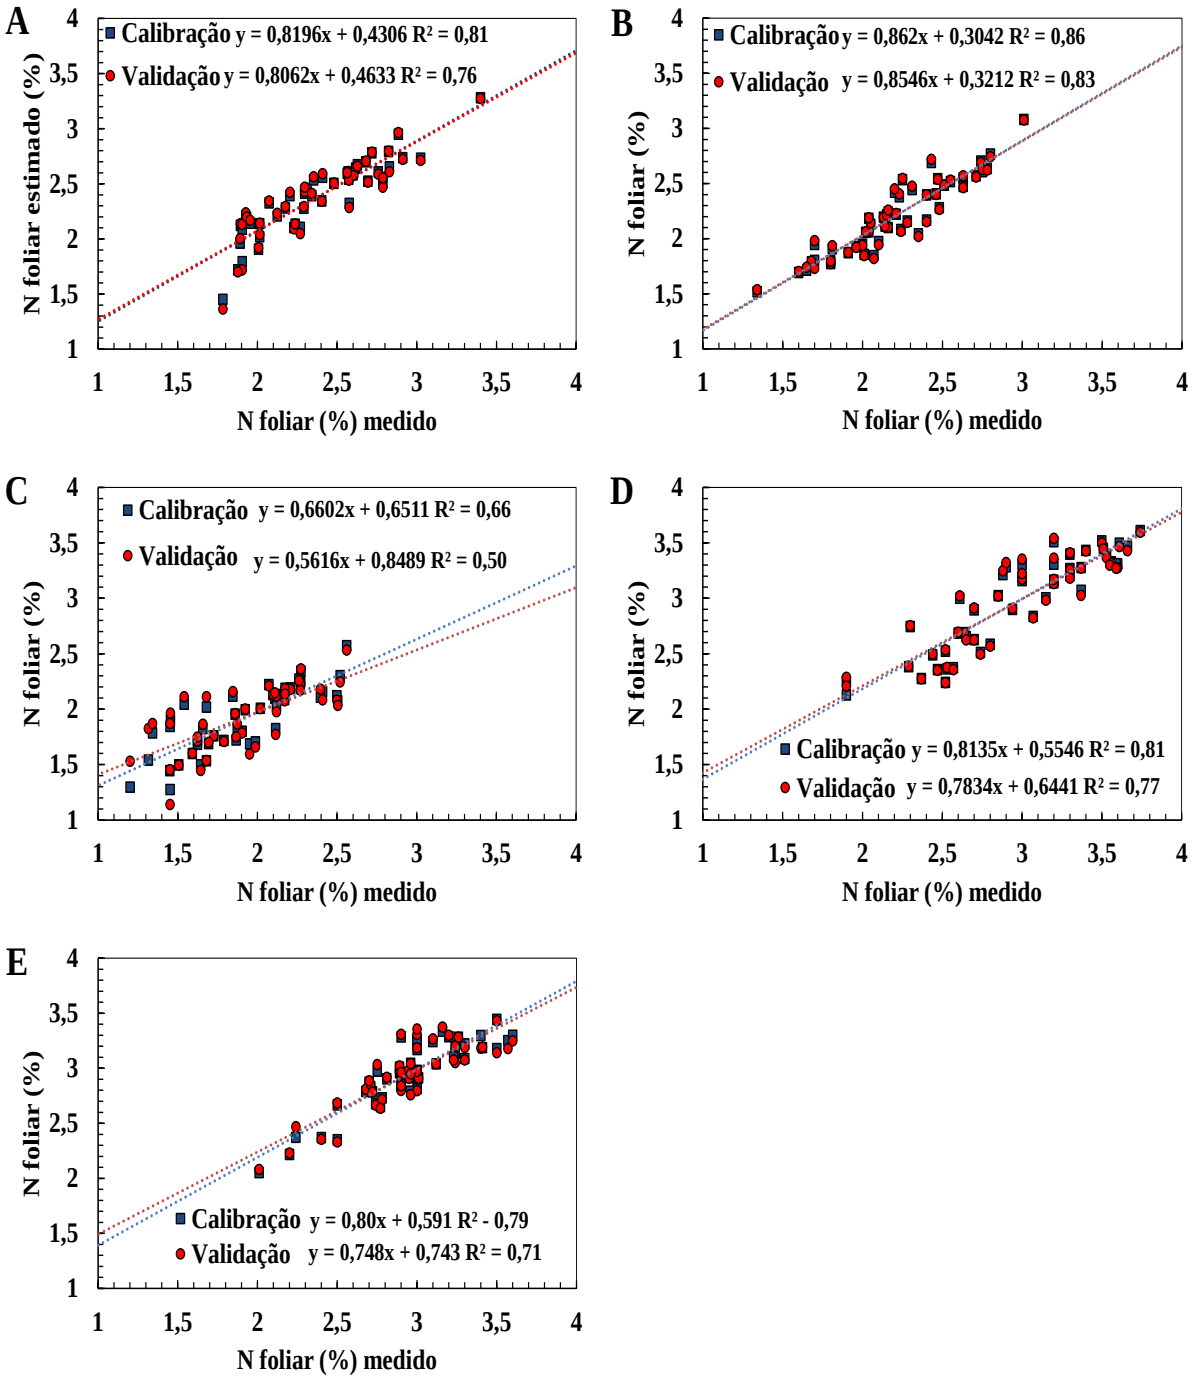


Fonte: elaboração do autor.

Figura 45 - Equações de validação entre os modelos PLSR e a concentração de N foliar para dados de campo. (A) estádio V8 2015; (B) estádio R1 2015; (C) estádio R3 2015; (D) estádio V8 2016 e (E) estádio R3 2016

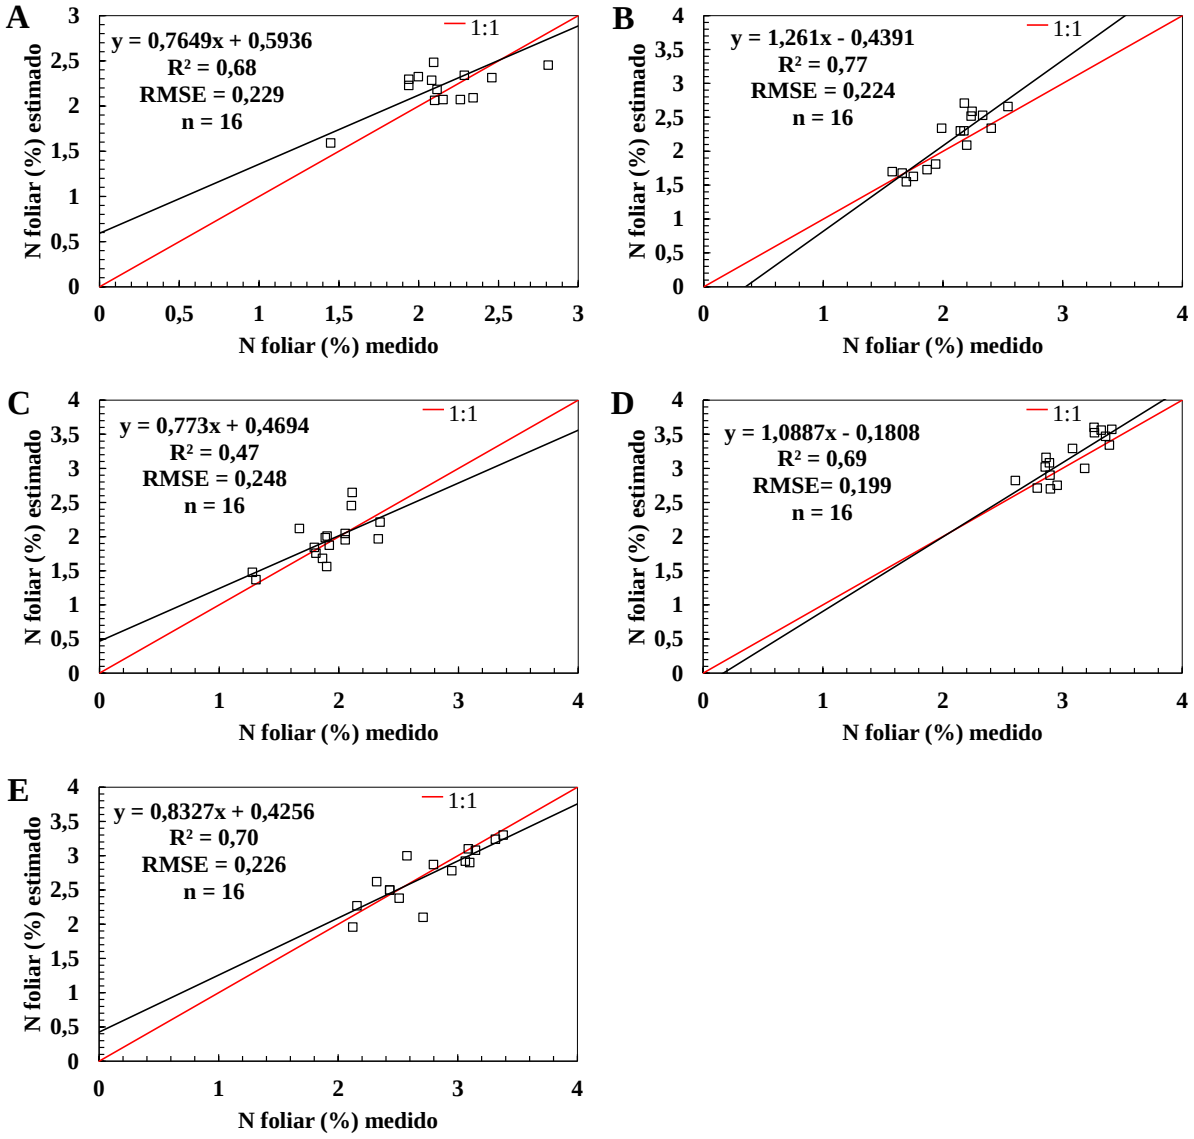


Fonte: elaboração do autor.

## Discussão

### *Modelos de bandas individuais e a concentração de N foliar*

Os resultados do correlograma de Pearson (*r*) entre a reflectância da folha e a concentração de N foliar, mostraram que as correlações mais fortes estão localizadas no visível, especialmente próximo ao vermelho (400 nm a 720 nm) e ocorrendo de forma negativa. Para os dados de laboratório os valores mais expressivos foram observados entre a

faixa de 653 nm e 718 nm com *r* variando entre -0,722 e -0,738 (FIGURA 30). Nos dados de campo, verificou-se, além das correlações fortes no visível (r = -0,573 e -0,739), altos valores positivamente correlacionados no infravermelho (750 nm a 850 nm), com *r* variando entre 0,662 e 0,563 (FIGURA 33). No entanto, os valores mais significativos de *r* foram observados no visível entre as faixas 667 nm e 684 nm. A grande importância dessa faixa está relacionada a absorção de REM pelos pigmentos de clorofila que apresentam alta correlação com o N (HUNT *et al.,* 2013; CORTI *et al.,* 2017). Vários estudos anteriores já indicaram a forte relação entre as bandas do VIS (400 nm a 720 nm) e o N foliar, mostrando ser essa região indicada para obtenção de bandas espectrais relacionadas a condição nutricional de plantas (ZHU *et al.,* 2006; INOUE *et al.,* 2016;). Quanto aos valores positivamente correlacionados com o N foliar no infravermelho, deve-se principalmente a influência da estrutura celular do mesófilo vegetal (HEEGE *et al.,* 2008). Segundo Schlemmer *et al.* (2013), o aumento do índice de área foliar e biomassa resultante de plantas bem fertilizadas, interferem fortemente no fator de reflectância, principalmente na região do infravermelho. Dessa forma, mudanças estruturas no tecido foliar devido à variações no suprimento nutricional, a exemplo da disponibilidade de N, têm efeito considerável na resposta nessa faixa. Porém, essas influências no espectro foram mais bem observadas em dados coletados em campo, em nível de dossel. A coleta de dados em nível de folha tendeu a minimizar essa resposta.

Os modelos gerados a partir das bandas individuais para os dados de laboratório produziram melhor desempenho do que os de campo (FIGURAS 32 e 35). As condições controladas de laboratório permitiram evidenciar melhor as bandas de absorção para todas as avaliações em relação às de campo, com exceção do R3 2016 (r = 0,739). Dessa foram, os melhores resultados para esse tipo de abordagem em laboratório eram esperados.

***Índices normalizados de N foliar***

A elevada quantidade de bandas espectrais permitiu a formulação de um grande número de combinações normalizadas. As regiões mais importantes para a formulação dos índices normalizados de nitrogênio foliar para dados de laboratório ficaram entre as faixas de 500 nm e 750 nm (posição j) e 800 nm e 1300 nm (posição i). A faixa entre 1600 nm a 1800 nm (posição j) também apresentaram moderada importância (FIGURA 36). Para dados coletados em campo, as melhores combinações de bandas estão localizadas entre as faixas 700 nm a 1300 nm (posição i) e 400 nm a 500 nm (posição j) e entre 600 nm 700 nm (posição

j) (FIGURA 39). As bandas selecionadas para compor os índices (FIGURAS 37 e 40), demonstram e confirmam a importância das regiões entre as faixas 600 nm e 800 nm, posição denominada pela literatura como “borda vermelha” e o de infravermelho próximo (NIR), especialmente entre 800 nm e 1300 nm. A borda vermelha é uma região importante na estimativa de parâmetros bioquímicos e biofísicos por meio de dados espectrais. Essa faixa tem sido utilizada para extração de comprimentos de onda relacionadas com estresse por deficiência nutricional (MIPHOKASAP *et al.*, 2012).

Em estudo com plantas de milho, Cho e Skidmore (2006), avaliaram a reflectância em função da adubação nitrogenada por meio de dados hiperespectrais e verificaram alta sensibilidade da concentração de N foliar na faixa entre 680 nm a 725 nm. Ainda para a cultura do milho, Chen *et al.* (2010) observaram que o índice formulado a partir de pontos médios de bandas centradas entre 670 nm e 720 nm têm grande potencial para expressar alterações de N foliar. Clevers e Gitelson (2013) evidenciaram a faixa localizada entre 724 nm e 800 nm como a mais eficiente para descrever alterações no espectro em ralação a mudanças no nitrogênio foliar em várias culturas, incluindo o milho. Resultados significativos em estudo realizado por Quemada *et al.* (2014), utilizando dados de imagens hiperespectrais na diagnose nutricional do milho, constataram que a relação entre as bandas 750 e 710 nm, foram mais precisos na diferenciação de plantas em relação às doses de N.

Com relação ao desempenho de índices normalizados de N foliar, os melhores despenhos foram obtidos com o modelo R1 2016 ([910-690]/[910+690]) em laboratório ($R^2$ = 0,80 e RMSE = 0,20) e o modelo R3 ([762-684]/[762+684]) em campo ($R^2$ = 0,78 e RMSE = 0,20) (FIGURAS 38 e 41). Segundo Feng *et al.* (2016), a precisão da capacidade preditiva de índices depende muito do conjunto de dados utilizados e, portanto, de fatores como estádio de crescimento e tipo de coleta de dados, o que pode resultar em diferentes valores de $R^2$. Essa variação no ajuste entre os estádios de crescimento está intimamente ligada a mudanças na estrutura do dossel e pela diluição do N, ao passo que a cultura avança para o estágio reprodutivo (FENG *et al.*, 2016; XIA *et al.*, 2016).

Quanto a seleção de bandas para formulação dos índices, os comprimentos de onda centrados em torno de 700 e 750 nm são estabelecidos como uma faixa sensível a variações de clorofila e N foliar em diversas culturas (INOUE *et al.*, 2012; MIPHOKASAP *et al.*, 2012; INOUE *et al.*, 2016). Por esse motivo, vários índices normalizados baseados em bandas dessa faixa têm sido sugeridos. O desempenho dos melhores índices encontrados neste trabalho é semelhante aos encontrados por Wang *et al.* (2017) para a cultura do milho usando

as bandas 715 nm e 716 nm ($R^2$ = 0,82) em condições de laboratório. Os resultados são ligeiramente maiores que encontrados para o milho por Zhou *et al.* (2010) utilizando as bandas 714 nm e 544 nm ($R^2$ = 0,74) também em laboratório e para o trigo por Feng *et al.* (2016), utilizando as bandas 720 nm e 735 nm ($R^2$ = 0,77) em condições de campo. Os resultados são ainda equivalentes quanto ao desempenho em relação a outras estratégias de obtenção de NDNI, a exemplo de Shi *et al.* (2015), que utilizaram a reamostragem do espectro de reflectância em bandas de 10 nm conseguindo $R^2$ = 0,81 utilizando as bandas 1790 nm e 1570 nm para cultura do milho e leitura em laboratório. No entanto, desempenhos superiores podem ser encontrados na literatura para outras espécies de gramíneas, a exemplo de Inoue *et al.* (2012), que alcançaram $R^2$ = 0,90 usando as bandas 825 nm e 735 nm para cultura do arroz.

***Modelos PLSR***

Os modelos PLSR produziram resultados diferentes, dependendo do nível de coleta de dados e estádio fenológico da cultura. Com exceção do modelo V8 2016 em laboratório (RMSEP = 0,35), o erro médio quadrático da predição manteve-se abaixo de 0,248 (TABELAS 11 e 12). Quanto ao desempenho geral, o modelo R1 2016 ($R^2$ = 0,82 e RMSEP = 0,190) em laboratório, resultou na melhor capacidade de acerto entre todos os modelos e índices gerados para os três estádios fenológicos nesse trabalho (TABELA 11 e FIGURA 43). Para o mesmo estádio fenológico R1, verificou-se o melhor resultado para o índice normalizado R1 2016 ($R^2$ = 0,80 e RMSE = 0,200) (FIGURA 38). Os modelos PLSR gerados com dados de campo no R1 2015 ($R^2$ = 0,77 e RMSP = 0,224) também produziram os melhores resultados para esse tipo de coleta. Esses resultados mostram o grande potencial do estádio R1 do milho para o desenvolvimento de modelos preditivos do nitrogênio foliar nessa cultura. Quanto ao desempenho em função dos estádios fenológicos, como comentado anteriormente, este sofre grande influência de fatores como diluição e mudanças de biomassa durante o ciclo de desenvolvimento da cultura (FENG *et al.*, 2016). No entanto, o melhor estádio para obtenção de modelos preditivos de N não é bem estabelecido na literatura. Essa questão está mais relacionada com a época mais importante da curva de absorção da cultura. Porém encontram-se vários resultados sugerindo as épocas mais adequadas ou que melhor respondem a índices de vegetação para o milho, a exemplo de Xia *et al.*, (2016), que acharam melhores resultados no V5 ao V8, Sharma *et al.*, (2015) no estádio V12 e Quemada *et al.*,

(2014) que observaram maior sensibilidade de índices de vegetação para diferencia tratamentos de nitrogênio em milho na fase de florescimento (equivalente nesse estudo entre R1 e R3) do que na fase de crescimento.

Apesar de modelos baseados em uma única banda (BIs) apresentarem melhores ajuste para dados de validação no estádio R3 e V8, esses apresentam baixo ajuste nos modelos de calibração ($R^2$>0,55) e RMSE variando entre 0,23 e 0,34 (FIGURA 32) muito acima dos encontrados para modelos PLSR. Segundo Zhai *et al.* (2013), a PLSR permite a maior capacidade para explorar informações que muitas vezes foram suprimidas por outros métodos de análise.

No geral, os resultados dos melhores ajustes dos modelos PLSR em laboratório desse trabalho foram superiores aos obtidos por Wang *et al.,* (2017) para a cultura do milho. Os melhores modelos tiveram ainda desempenho superior aos achados por Zhai *et al.* (2013), que desenvolveram um modelo baseado em dados de diversas culturas agrícolas, incluindo o milho ($R^2$ = 0,663 e RMSEv = 0,577). Com relação ao potencial de validação com dados independentes, verificou-se que os resultados foram superiores aos obtidos por Yuan *et al.* (2016) para milho doce ($R^2$ = 0,67) em condições de laboratório.

A análise dos melhores resultados de modelos PLSR obtidos permitem concluir que os dados de laboratório produziram modelos superiores em todos os estádios fenológicos em relação aos dados de campo, com exceção de apenas um caso no R3 2016 CAMPO ($R^2$ = 0,70). Os dados obtidos em laboratório permitiram desenvolver os modelos utilizando todas as bandas espectrais, incluindo as características de absorção de água e que geram ruídos em condições de campo (1350 nm a 1450 nm; 1800 nm a 1970 nm e 2400 nm a 2500 nm). Enquanto que os modelos de campo foram desenvolvidos com bandas entre as faixas 350 nm a 1300 nm. Essa diferença entre a quantidade de informação influenciou no valor da variância explicada pelos preditores para os modelos de cada nível de obtenção de dados, de tal forma que, a variância explicada para modelos em laboratório variou entre 93,89% a 94,45%, enquanto que para o campo variou entre 96,97% a 98,88% da variância acumulada para o melhor modelo (TABELAS 11 e 12). Isso mostra que a redução do número de bandas aumentou a capacidade de explicação do modelo de calibração mais não resultou necessariamente em melhor desempenho. Esses resultados destoam das observações constatadas por Wang *et al.,* (2017) em estudo da influência da disponibilidade hídrica na predição de N foliar. Segundo os mesmos autores, a absorção de água tem efeitos limitados na redução da precisão da estimativa de nitrogênio na folha, sendo que a remoção das faixas

espectrais sensíveis à água pode reduzir a precisão devido à perda de informação espectral. No entanto, essa influência pode ser minimizada, visto que, como mostrado nesse trabalho, a faixa com coeficientes de correlação mais importante está centrada no visível e borda vermelha.

**Conclusões**

Os resultados obtidos permitem concluir que sob condições de laboratório e campo, a concentração de N foliar em plantas de milho pode ser quantificada a partir de dados de espectroscopia de reflectância. Os modelos desenvolvidos em laboratório produziram em sua maioria, melhor desempenho que os de campo em todos os estádios fenológicos testados. O melhor modelo para laboratório pode ser obtido usando regressão por mínimos quadrados parciais (PLSR) no estádio R1 da cultura ($R^2$ = 0,82 e RMSEP = 0,190). Para dados de campo o melhor modelo pode ser obtido pela razão normalizadas das bandas 762 nm e 684 nm para o estádio R3 ($R^2$ = 0,78 e RMSE = 0,20). Conclui-se que a modelagem é influenciada pelos estádios fenológicos e pelo nível de coleta de dados, reforçando a importância do ajuste de modelos preditivos em função das diferentes fases de crescimento da cultura.

# REFERÊNCIAS


ATZBERGER, C.; GUÉRIF, M.; BARET, F.; WERNER, W. Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat. **Computers and Electronics in Agriculture**, v. 73, n. 2, p. 165-173, 2010.

BASSO, B.; FIORENTINO, C.; CAMMARANO, D.; SCHULTHESS, U. Variable rate nitrogen fertilizer response in wheat using remote sensing. **Precision agriculture**, v. 17, n. 2, p. 168-182, 2016.

CHEN, P.; HABOUDANE, D.; TREMBLAY, N.; WANG, J.; VIGNEAULT, P.; LI, B. New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. **Remote Sensing of Environment**, v.114, p.1987–1997, 2010.

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

CILIA, C.; PANIGADA, C.; ROSSINI, M.; MERONI, M.; BUSETTO, L.; AMADUCCI, S.; COLOMBO, R. Nitrogen status assessment for variable rate fertilization in maize through hyperspectral imagery. **Remote Sensing**, v. 6, n. 7, p. 6549-6565, 2014.

CLEVERS, J. G. P. W.; GITELSON, A. A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and-3. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 344-351, 2013.

CORTI, M.; GALLINA, P. M.; CAVALLI, D.; CABASSI, G. Hyperspectral imaging of spinach canopy under combined water and nitrogen stress to estimate biomass, water, and nitrogen content. **Biosystems Engineering**, v. 158, p. 38-50, 2017.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; DE COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.

FAO - Food And Agriculture Organization of The United Nations. Statistics Division. 2015. Disponível em: < http://faostat3.fao.org/>. Acesso em: 18 Abr. 2016.

FENG, W.; ZHANG, H. Y.; ZHANG, Y. S.; QI, S. L.; HENG, Y. R.; GUO, B. B.; GUO, T. C. Remote detection of canopy leaf nitrogen concentration in winter wheat by using water resistance vegetation indices from in-situ hyperspectral data. **Field Crops Research**, v. 198, p. 238-246, 2016.

GONZALEZ-DUGO, V.; DURAND, J.; GASTAL, F. Water deficit and nitrogen nutrition of crops. A review. **Agronomy for sustainable development**, v. 30, n. 3, p. 529-544, 2010.

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.

HUNT, E. R.; DORAISWAMY, P. C.; MCMURTREY, J. E.; DAUGHTRY, C. S.; PERRY, E. M.; AKHMEDOV, B. A visible band index for remote sensing leaf chlorophyll content at

the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 103-112, 2013.

INOUE, Y., SAKAIYA, E., ZHU, Y., & TAKAHASHI, W. Diagnostic mapping of canopy nitrogen content in rice based on hyperspectral measurements. **Remote Sensing of Environment**, v. 126, p. 210-221, 2012.

INOUE, Y.; GUÉRIF, M.; BARET, F.; SKIDMORE, A.; GITELSON, A.; SCHLERF, M.; OLIOSO, A. Simple and robust methods for remote sensing of canopy chlorophyll content: a comparative analysis of hyperspectral data for different types of vegetation. **Plant, cell & environment**, v. 39, n. 12, p. 2609-2623, 2016.

JIA, X.; SHAO, L.; LIU, P.; ZHAO, B.; GU, L.; DONG, S.; ZHAO, B. Effect of different nitrogen and irrigation treatments on yield and nitrate leaching of summer maize (*Zea mays* L.) under lysimeter conditions. **Agricultural Water Management**, v. 137, p. 92-103, 2014.

LENKA, S.; SINGH, A. K.; LENKA, N. K. Soil water and nitrogen interaction effect on residual soil nitrate and crop nitrogen recovery under maize–wheat cropping system in the semi-arid region of northern India. **Agriculture, ecosystems & environment**, v. 179, p. 108-115, 2013.

LI, F.; MIAO, Y.; FENG, G.; YUAN, F.; YUE, S.; GAO, X.; CHEN, X. Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. **Field Crops Research**, v. 157, p. 111-123, 2014.

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.

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

RYU, C.; SUGURI, M.; UMEDA, M. Multivariate analysis of nitrogen content for rice at the heading stage using reflectance of airborne hyperspectral remote sensing. **Field Crops Research**, v. 122, n. 3, p. 214-224, 2011.

SCHLEMMER, M.; GITELSON, A.; SCHEPERS, J.; FERGUSON, R.; PENG, Y.; SHANAHAN, J.; RUNDQUIST, D. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. **International Journal of Applied Earth Observation and Geoinformation**, v. 25, p. 47-54, 2013.

SHARMA, L. K.; BU, H.; DENTON, A.; FRANZEN, D. W. Active-optical sensors using red NDVI compared to red edge NDVI for Prediction of corn grain yield in North Dakota, USA. **Sensors**, v. 15, n. 11, p. 27832-27853, 2015.

SHI, T.; WANG, J.; LIU, H.; WU, G. Estimating leaf nitrogen concentration in heterogeneous crop plants from hyperspectral reflectance. **International Journal of Remote Sensing**, v. 36, n. 18, p. 4652-4667, 2015.

TOBIAS, Randall D. et al. An introduction to partial least squares regression. In: **Proceedings of the twentieth annual SAS users group international conference**. SAS Institute Cary, NC, 1995. p. 1250-1257.

TRACHSEL, S.; SAN VICENTE, F. M.; SUAREZ, E. A.; RODRIGUEZ, C. S.; ATLIN, G. N. Effects of planting density and nitrogen fertilization level on grain yield and harvest index in seven modern tropical maize hybrids (*Zea mays* L.). **The Journal of Agricultural Science**, v. 154, n. 4, p. 689-704, 2016.

WANG, B. J.; CHEN, J. M.; JU, W.; QIU, F.; ZHANG, Q.; FANG, M.; CHEN, F. Limited Effects of Water Absorption on Reducing the Accuracy of Leaf Nitrogen Estimation. **Remote Sensing**, v. 9, n. 3, p. 291, 2017.

WANG, L.; WEI, Y. Revised normalized difference nitrogen index (NDNI) for estimating canopy nitrogen concentration in wetlands. **Optik-International Journal for Light and Electron Optics**, v. 127, n. 19, p. 7676-7688, 2016.

WANG, Z.; WANG, T.; DARVISHZADEH, R.; SKIDMORE, A. K.; JONES, S.; SUAREZ, L.; HEARNE, J. Vegetation indices for mapping canopy foliar nitrogen in a mixed temperate forest. **Remote Sensing**, v. 8, n. 6, p. 491, 2016.

WEI, S.; WANG, X.; SHI, D.; LI, Y.; ZHANG, J.; LIU, P.; DONG, S. The mechanisms of low nitrogen induced weakened photosynthesis in summer maize (*Zea mays* L.) under field conditions. **Plant Physiology and Biochemistry**, v. 105, p. 118-128, 2016.

WOLD, S.; SJÖSTRÖM, M.; ERIKSSON, L. (2001). PLS-regression: A basic tool of chemometrics. **Chemometrics and Intelligent Laboratory Systems**, v. 58, n. 2, p. 109-130, out. 2001.

XIA, T.; MIAO, Y.; WU, D.; SHAO, H.; KHOSLA, R.; MI, G. Active optical sensing of spring maize for in-season diagnosis of nitrogen status based on nitrogen nutrition index. **Remote Sensing**, v. 8, n. 7, p. 605, 2016.

YU, K.; LI, F.; GNYP, M. L.; MIAO, Y.; BARETH, G.; CHEN, X. Remotely detecting canopy nitrogen concentration and uptake of paddy rice in the Northeast China Plain. **ISPRS journal of photogrammetry and remote sensing**, v. 78, p. 102-115, 2013.

YUAN, M.; COUTURE, J. J.; TOWNSEND, P. A.; RUARK, M. D.; BLAND, W. L. Spectroscopic Determination of Leaf Nitrogen Concentration and Mass Per Area in Sweet Corn and Snap Bean. **Agronomy Journal**, v. 108, n. 6, p. 2519-2526, 2016.

ZHAI, Y.; CUI, L.; ZHOU, X.; GAO, Y.; FEI, T.; GAO, W. Estimation of nitrogen, phosphorus, and potassium contents in the leaves of different plants using laboratory-based visible and near-infrared reflectance spectroscopy: comparison of partial least-square regression and support vector machine regression methods. **International journal of remote sensing**, v. 34, n. 7, p. 2502-2518, 2013.

ZHOU, L.; FENG, H.; YAN, Z.; LIU, K.; ZHOU, S. Hyperspectral diagnosis of leaf N concentration of maize and variety difference. **Transactions of the Chinese Society of Agricultural Engineering**, v. 26, n. 8, p. 195-199, 2010.

ZHOU, X.; HUANG, W.; KONG, W.; YE, H.; LUO, J.; CHEN, P. Remote estimation of canopy nitrogen content in winter wheat using airborne hyperspectral reflectance measurements. **Advances in Space Research**, v. 58, n. 9, p. 1627-1637, 2016.

ZHU, Y.; LI, Y.; FENG, W.; TIAN, Y.; YAO, X.; CAO, W. Monitoring leaf nitrogen in wheat using canopy reflectance spectra. **Canadian Journal of Plant Science**, v. 86, n. 4, p. 1037-1046, 2006.

# 6 ESTIMATIVA DA CONCENTRAÇÃO DE NITROGÊNIO EM DOSSÉIS DE MILHO ATRAVÉS DE IMAGENS HIPERESPECTRAIS

## RESUMO

A estimativa da concentração de nitrogênio (N) em dosséis agrícolas a partir de sensores hiperespectrais pode contribuir para o monitoramento e otimização do manejo de fertilizantes nas culturas, proporcionando benefícios tanto agronômicos quanto ambientais. Portanto, objetivou-se usar imagens hiperespectrais obtidos com o sensor aerotransportado ProSpecTIR-SV, para estimar de N foliar na cultura do milho (*Zea mays* L.) em diferentes estádios de crescimento, visando avaliar o potencial dessa ferramenta no manejo da adubação. Amostras de N foliar do dossel de plantas foram coletadas em diferentes campos de cultivos de milho nos estádios vegetativo e reprodutivo, durante o voo no primeiro semestre de 2015. Foram desenvolvidos modelos para os dois estádios separadamente e um modelo misto utilizando os dois conjuntos de dados. O procedimento de seleção de bandas espectrais pelo método stepwise forward foi utilizado junto com a regressão por mínimos quadrados parciais (PLSR) para o desenvolvimento dos modelos. Os dados do estádio reprodutivo mostraram melhor performance na estimativa do N ($R^2$= 0,844, RMSECV= 1,0114 e RPD = 2,388). O modelo misto (1m+2m) foi menos preciso em relação aos modelos inviduais. O potencial das imagens para a criação de mapas de fertilidade de N foi confirmado com precisão com RMSECV variando entre 1,014 e 2,082 g $kg^{-1}$ N. Finalmente, a seleção de bandas juntamente com a PLSR é promissora para detecção de N em dosséis de milho.

**Palavras-chave:** Hiperespectral. *Zea mays* L. Agricultura de precisão. PLSR.

## ABSTRACT

The estimation of nitrogen (N) concentration in agricultural canopies from hyperspectral sensors can contribute to the monitoring and optimization of fertilizer management in the crops, providing both agronomic and environmental benefits. Therefore, the objective was to use hyperspectral images obtained with the ProSpecTIR-SV airborne sensor to estimate leaf N in maize (*Zea mays* L.) at different stages of growth, in order to evaluate the potential of this

tool in the management of fertilization. Leaf nitrogen samples from the canopy of plants were collected in different fields of maize crop in the vegetative and reproductive stages during the first half of 2015. Models were developed for the two stages separately and a mixed model using the two datasets. The stepwise forward spectral band selection procedure was used in conjunction with the partial least squares regression (PLSR) for the development of the models. Data from the reproductive stage showed a better performance in N estimation ($R^2$ = 0.844, RMSECV = 1.0114 and RPD = 2.388). The mixed model (1m + 2m) was less precise than the individual models. The potential for creating images of N fertility maps accurately confirmed with RMSECV varying between 2.082 and 1.014 g $kg^{-1}$ N . Finally, the selection of bands together with the N PLSR is promising for detection in corn canopies.
**Keywords:** Hyperspectral. *Zea mays* L. Precision agriculture. PLSR.

## Introdução

Dentre os nutrientes exigidos pelas culturas, o nitrogênio (N) é o que mais limita a produtividade primária líquida, desempenhando importante função no metabolismo fotossintético e nutrição das plantas (WEI *et al.,* 2016). Assim, os ganhos de rendimento nas plantas cultivadas, a exemplo do milho (*Zea mays* L.), dependem, em grande parte, do manejo adequado da adubação (TRACHSEL *et al.,* 2016). A deficiência de N ocasiona desordem nutricional, enquanto que a aplicação em excesso ocasiona sérios impactos ambientais como a contaminação de águas superficiais e subterrâneas por nitrato, devido perdas por lixiviação (JIA *et al.,* 2014). Dessa forma, um grande número de pesquisas está direcionado na otimização do uso de fertilizantes nitrogenados pelas culturas e a diminuição dos riscos ambientais e impactos econômicos (LENKA *et al.,* 2013; MUÑOZ-HUERTA *et al.,* 2013). Visto o cenário de previsão de aumento de uso de fertilizantes nos próximos anos, a melhoria da eficiência do uso desses insumos, através da utilização racional de nutrientes, pode proporcionar benefícios tanto agronômicos como ambientais (PIRES *et al.,* 2015).

Com o propósito de melhorar os sistemas de manejo de adubação, métodos não destrutivos têm sido desenvolvidos para a estimativa da condição nutricional de plantas. Especificamente, métodos baseados em dados de sensoriamento remoto têm despertado grande interesse, por apresentarem grande potencial de utilização na otimização das técnicas de aplicação de fertilizantes (QUEMADA *et al.* 2014; XIA *et al.,* 2016). Recentemente, modelos preditivos do N foliar gerados a partir de dados hiperespectrais têm sido

desenvolvidos e sugeridos para várias culturas agrícolas (SHI *et al.*, 2015; GABRIEL *et al.*, 2017). Estudos com imagens hiperespectrais obtidos por sensores aerotransportados mostram resultados promissores na utilização de dados de alta resolução espectral na criação de mapas de fertilidade baseadas no estado nutricional da planta (CILIA *et al.*, 2014). As informações geradas com estas plataformas podem ser utilizadas no monitoramento do status de N ao longo do crescimento da cultura e previsão de produtividade (INOUE *et al.*, 2012).

As informações provenientes de dados com maior nível de detalhamento espectral possibilitam a análise aprimorada de faixas específicas relacionadas ao conteúdo dos constituintes bioquímicos das folhas, permitindo a definição de regiões do espectro de acordo com o coeficiente de absorção de cada componente e de maneira mais robusta (FEILHAUER *et al.*, 2015). Dessa forma, a seleção de comprimentos de onda específicos relacionados a concentração de N foliar proporcionam melhorias no desempenho dos modelos preditivos (MIPHOKASAP *et al.*, 2012; WANG *et al.*, 2017). Além disso, a seleção de variáveis pode ser relevante para reduzir o risco de *overfitting*, ou superajuste dos dados (ANDERSEN; BRO, 2010).

No entanto, a aplicação desse tipo de modelagem na quantificação de N foliar em uma determinada cultura pode ter a precisão comprometida por fatores de confusão, visto o grande número de dados gerados, ocasionados por diversos fatores como tipo de coleta de dados, estádio de desenvolvimento, tipos de cultivar e diluição do N foliar durante o ciclo (FENG *et al.*, 2016). Modelos de regressão multivariados como PLRS (*Partial least square regression*) têm mostrado a capacidade para lidar como esse problema de heterogeneidade nos dados (RYU *et al.*, 2011). Estudos anteriores mostram desempenhos satisfatórios da modelagem PLSR na estimativa de N foliar (ZHAI *et al.*, 2013; DUNN *et al.*, 2016). Na PLSR, todos os comprimentos de onda são analisados de maneira ponderada para a formulação de um modelo preditivo, permitindo melhorias no desempenho e ainda a possibilidade de analisar a importância das regiões do espectro utilizados nessa predição (ATZBERGER *et al.*, 2010; YUAN *et al.*, 2016).

O que justifica o interesse em estudos sobre a avaliação nutricional de plantas por meio de sensoriamento remoto é a possibilidade do desenvolvimento de técnicas que melhorem o gerenciamento do processo produtivo, permitindo a otimização dos sistemas agrícolas (PENG; GITELSON, 2012; SHARMA *et al.*, 2015).

Diante do exposto, este trabalho tem como principais objetivos: i) avaliar o desempenho do uso de imagens hiperespectrais, obtidas com o sensor aerotransportado

ProSpecTIR-SV, para estimar a concentração de nitrogênio N foliar na cultura do milho; ii) avaliar o desempenho das técnicas de seleção de bandas e regressão PLSR para a obtenção de modelos preditivos do teor de N foliar e iii) investigar como os dados obtidos em diferentes estádios de desenvolvimento influenciam na modelagem do status de N no dossel.

## Material e métodos

### *Área de estudo*

O estudo foi realizado em uma área localizada no Perímetro Irrigado Jaguaribe-Apodi, município de Limoeiro do Norte, Estado do Ceará, entre as coordenadas 5° 7' S e 37° 58' O e 5° 13' S e 38° 3' O (FIGURA 46).

Figura 46 - Localização da área de estudo

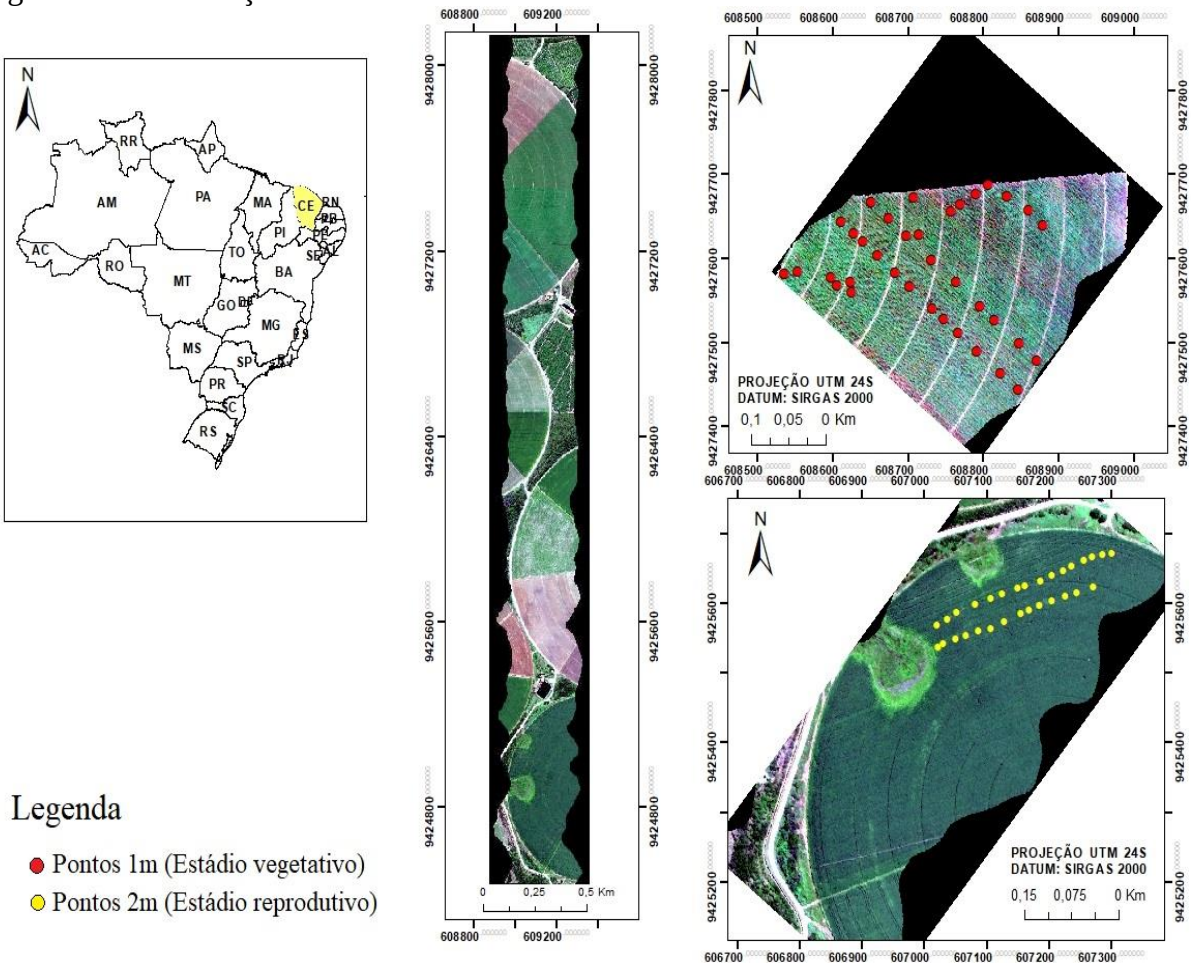


Fonte: elaboração do autor.

O clima da região, segundo classificação de Köeppen, é do tipo BSw'h' (clima quente e semiárido, com estação chuvosa podendo atrasar para o outono), com temperatura média anual de 28,5 °C, mínima de 22 °C e máxima de 35°C. A precipitação pluviométrica média anual é de 772 mm, irregularmente distribuídas. A umidade relativa média anual fica em torno de 62%, evapotranspiração de 3.215 mm $ano^{-1}$ e insolação de 3.030 horas/ano (DNOCS, 2016).

O relevo é plano com declividade dominante inferior a 2%, observando-se apenas pequenas áreas ligeiramente deprimidas como variação nas condições da morfologia geral da área. A vegetação predominante e de caatinga hiperxerófila (DNOCS, 2016).

***Coleta de dados em campo e análise de N***

As amostras de folhas foram coletadas em dois locais específicos (FIGURA 46) em 18 de maio de 2015, em áreas cultivadas com milho em dois estádios de desenvolvimento: 1m (vegetativo) e 2m (reprodutivo). Foram coletadas amostras de folhas localizadas na porção média de quatro plantas espaçadas por 1 m. Os pontos foram georreferenciados por meio de equipamento de sistema de posicionamento global (GPS) para posterior coletada de dados rediométricos das imagens orbitais no local da amostragem. O material vegetal foi acondicionado e transportado para laboratório, onde posteriormente foi seco em estufa de circulação forçada de ar a 60°C (até peso constante). A solubilização das amostras de tecido vegetal foi realizada por meio de digestão sulfúrica e o N total determinado pelo método semi-micro Kjeldahl. Todos os procedimentos de análises químicas/nutricionais foram feitos no Laboratório de Análises de Solos e Tecidos Vegetais do Instituto Federal de Educação Ciência e Tecnologia do Ceará – Campus de Limoeiro do Norte

***Aquisição de dados hiperespectrais e tratamento dos dados***

Uma imagem hiperespectral foi adquirida com o sensor aerotransportado ProSpecTIR-SV operada pela Fototerra Company em 18 de maio de 2015 sobre áreas cultivadas com milho. As características e parâmetros de aquisição são apresentados na Tabela 13.

Tabela 13 – Características e parâmetros de aquisição das imagens

| Sensor | Range espectral (nm) | Número de bandas | Resolução espectral (nm) | Resolução espacial (m) | Hora do voo (UTC) |
|---|---|---|---|---|---|
| ProSpecTIR-SV | 400 - 2500 | 357 | 5,0 | 1,0 | 12:39 |

Fonte: elaboração do autor.

A correção dos efeitos da dispersão e absorção por gases atmosféricos dos dados de radiância e a posterior conversão para reflectância de superfície foi realizada pelo programa de transferência radiativa ATCOR4. Foi adotado um modelo atmosférico tropical rural. Os efeitos do vapor de água foram calculados usando as bandas de absorção localizadas a 940 nm e 1130 nm.

Para a correção geométrica da imagem foram utilizados dados do ponto de inércia do sistema de navegação da aeronave. Os espectros das imagens specTIR foram amostrados por meio do software ENVI 5.1.

***Análises estatísticas***

Inicialmente foi utilizado o recurso de seleção de bandas pelo método stepwise forward utilizando todos os comprimentos de ondas disponíveis (357 bandas, 400-2500 nm). O critério utilizado para seleção foi o maior coeficiente de determinação ajustado ($R^2$ ajustado).

Posteriormente, os modelos PLSR (regressão por mínimos quadrados parciais) foram calibrados com as bandas selecionadas. Finalmente, a capacidade preditiva dos modelos PLSR foi avaliado pelos valores de coeficiente de variação ($R^2$), raiz do erro quadrático médio (RMSECV) e desvio preditivo residual (RPD), usando a validação cruzada *leave one out* (LOOCV), conforme as equações a seguir.

$$R^2=1-\sum_{j=1}^{n}\left(y_j^{'}-y_i\right)^2 / \sum_{j=1}^{n}(y_j^{'}-\overline{y})^2 \quad (18)$$

$$RMSECV=\sqrt{\frac{\sum_{j=1}^{n}\left(y_j^{'}-y_i\right)^2}{n}} \quad (19)$$

$$RPD= SD/RMSECV \quad (20)$$

Em que, $y_j$ e $y'_j$ são os valores medidos e estimados pela validação cruzada do modelo, respectivamente, $\bar{y}$ é a médias dos valores observados, $n$ o número de observações e *SD* o desvio padrão da observações.

Para o tratamento dos dados e o desenvolvimento dos modelos foram utilizados os Softwares IBM® SPSS® e Unscrambler® X (CAMO software AS, Oslo, Norway).

**Resultados**

Na Tabela 14 é apresentada a estatística descritiva da concentração de N foliar para os dois conjuntos de dados.

Tabela 14 - Estatísticas descritivas dos conjuntos de amostras de N foliar

| Conjunto de dados | Estádio | n | Mín (g kg$^{-1}$) | Máx (g kg$^{-1}$) | Média (g kg$^{-1}$) | DP | CV (%) |
|---|---|---|---|---|---|---|---|
| Conjunto 1 (1m) | Vegetativo | 36 | 22,7 | 37,8 | 30,6 | 4,2 | 13,9 |
| Conjunto 2 (2m) | Reprodutivo | 30 | 22,2 | 32,8 | 27,8 | 2,4 | 8,6 |

n, número de dados; DP, desvio padrão; CV, coeficiente de variação (=média/DP x 100%). Fonte: elaboração do autor.

Os valores médios e o desvio padrão (DP) para os dados 1m e 2m foram 30,6 g kg$^{-1}$ (±13,9) e 27,8 (±8,6) g kg$^{-1}$, respectivamente. O coeficiente da variação (CV) foi maior para o conjunto 1m (vegetativo) (13,9%) em relação ao 2m (reprodutivo) (8,6%).

Na Figura 47 observam-se os espectros de reflectância representativos de dosséis de plantas de acordo com o nível de nitrogênio foliar nos dois sítios de coleta.

Figura 47 - Perfis espectrais de dosséis de plantas de milho com o incremento da concentração de N foliar para os conjuntos de dados 1m (A) e 2m (B), obtidos do sensor ProSpecTIR-VS

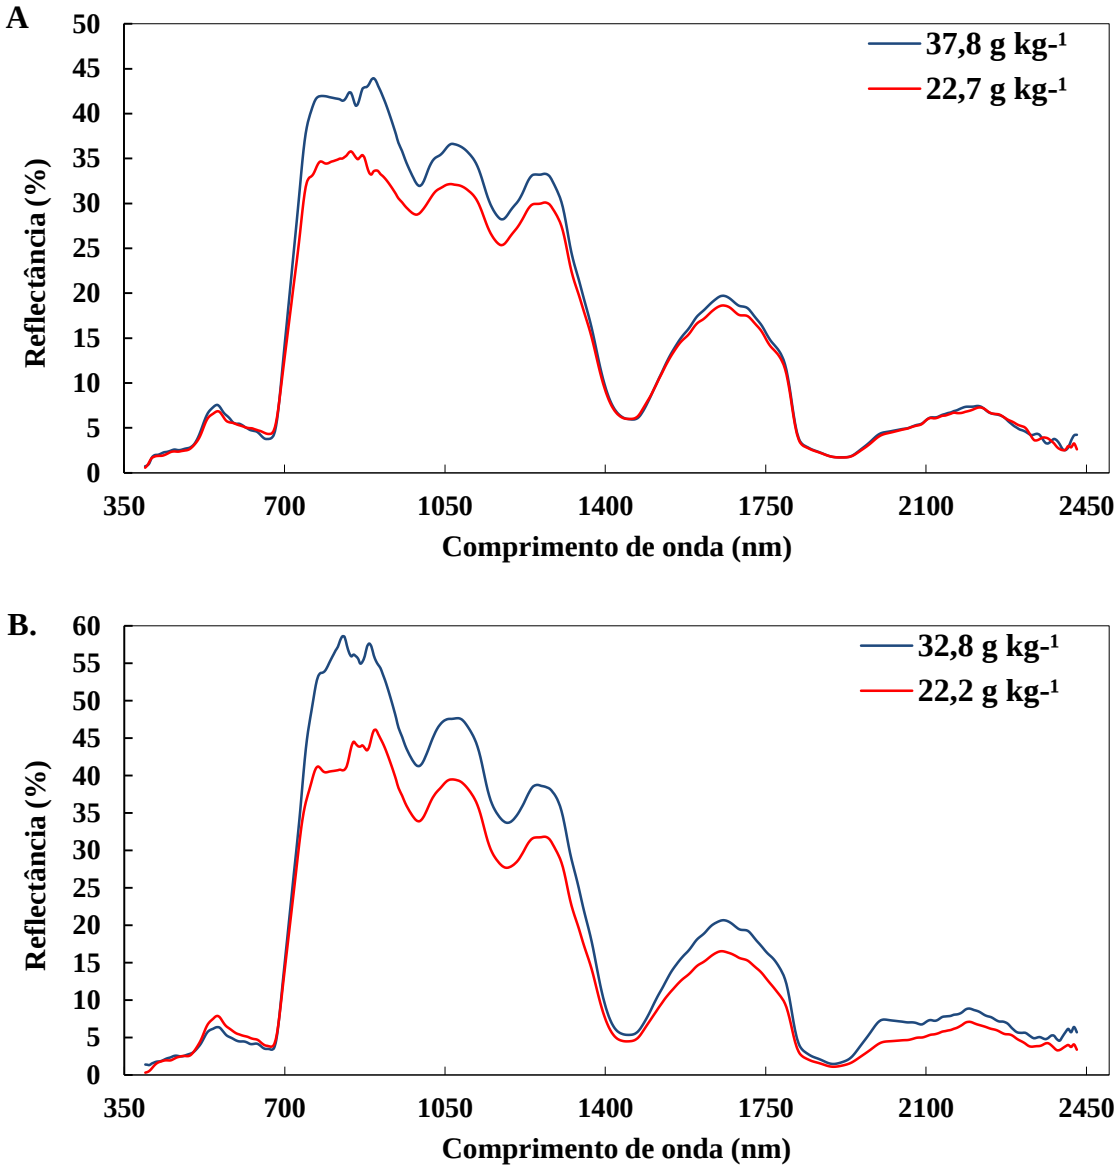


Fonte: elaboração do autor.

A reflectância apresenta aumento em regiões características do infravermelho (NIR) e no SWIR (1500 nm – 1750 nm) e menor diferenciação observável na faixa do visível entre 450-750 nm, expressas por diferentes valores de N foliar. O aumento da fertilização de N tem efeito considerável na resposta espectral nas faixas do visível (400 nm a 700 nm) e infravermelho próximo (800 nm a 1300 nm), ocasionados principalmente por mudanças no conteúdo de pigmentos de clorofila e no crescimento vegetal da cultura (MIPHOKASAP *et al.*, 2012; SCHLEMMER *et al.*, 2013).

Na Tabela 15 encontra-se os resultados da seleção das características para estimar N foliar obtidos pela regressão Stepwise. O melhor resultado foi obtido com reflectância de seis bandas localizadas em 451,12, 695,8, 792,05, 830,89, 879,7, 2447,97 nm ($R^2$ ajustado = 0,902) para o conjunto 2m. Quando utilizados todos os dados a seleção de bandas foi menos efetiva em relação aos conjuntos separados, resultado em valores baixos de $R^2$ ajustado (0,751) (TABELA 15).

Tabela 15 - Seleção de bandas espectrais para dados de reflectância a partir da análise das 357 bandas do sensor hiperespectral ProSpecTIR-VS

| Dados | Modelo | n | Bandas selecionadas | $R^2$ ajustado |
|---|---|---|---|---|
| Reflectância | 1m | 36 | 643,37, 676,7, 700,59, 787,21, 2379,32 nm | 0,824 |
| | 2m | 30 | 451,12, 695,8, 792,05, 830,89, 879,7, 2447,97 nm | 0,902 |
| | *Todos* | 66 | 437,25, 441,87, 667,16, 686,24, 1410,8, 1498,48, 2266,88, 2366,83, 2398,05 nm | 0,751 |

Fonte: elaboração do autor.

Considerando a diferença na precisão entre os modelos gerados 1m, 2m e todos (misto) (TABELA 16), constatou-se maior precisão preditiva para o modelo 2m ($R^2$ = 0,844, RMSECV= 1,014, RPD = 2,388). Os modelos 1m ($R^2$ = 0,780, RMSECV= 1,946, RPD = 2,180) e *todos* ($R^2$ = 0,710, RMSECV= 2,082, RPD = 1,820) produziram menor despenho.

Tabela 16 - Número de variáveis latentes ótimas (NVL), coeficiente de determinação ($R^2$), erro quadrado médio da calibração (RMSEC) e validação cruzada (RMSECV) e valores preditivos residuais (RPD) da PLSR do espectro de reflectância com o número de bandas espectrais selecionadas (NB)

| **Modelo** | **Calibração** | | | **Validação** | | | **NB** |
|---|---|---|---|---|---|---|---|
| | **NVL** | **$R^2$** | **RMSEC(g. $Kg^{-1}$)** | **$R^2$** | **RMSECV (g. $Kg^{-1}$)** | **RPD** | |
| 1m | 4 | 0,849 | 1,631 | 0,780 | 1,946 | 2,180 | 5 |
| 2m | 5 | 0,894 | 0,772 | 0,844 | 1,014 | 2,388 | 6 |
| Todos | 5 | 0,782 | 1,752 | 0,710 | 2,082 | 1,820 | 9 |

Fonte: elaboração do autor.

A Figura 48 mostra as relações entre os valores previstos e observados, validados pela validação cruzada. Estes resultados indicam que a concentração de N foliar na cultura do

milho pode ser prevista a partir dos espectros de reflectância obtidos das imagens ProSpecTIR-VS usando PLSR de bandas previamente selecionadas.

A seleção de características relacionadas a N foliar diminuiu a dimensionalidade dos dados espectrais mantendo as informações relevantes para previsão e, por conseguinte, melhorou o resultado da PLSR. Além disso, a diminuição do número de variáveis de entrada pela remoção de bandas com informação redundante contribui para o maior desempenho dos modelos gerados.

Tanto a robustez, como a capacidade preditiva de um determinado modelo são características importantes. O melhor resultado com base no RPD e RMSECV, foi o modelo 2m (RPD = 2,388, RMSECV = 1,014).

Em relação a capacidade de desempenho, o modelo 2m pode ser considerado como de boa capacidade de previsão (2 < RPD <3) (D'ACQUI *et al.*, 2010).

Se considerarmos o número de variáveis latentes como critério, o modelo 1m conseguiu atingir (RPD = 2,180) com apenas quarto variáveis latentes. Em termos de robustez, um modelo que usa menos variáveis latentes é menos propenso a problemas de *overfitting* em relação a modelos que usam mais variáveis latentes (ADNAN *et al.*, 2017).

As Figuras 49 e 50 mostram os valores de concentração de N foliar estimados pelos modelos 1m, 2m e 1m+2m aplicados à imagem do Sensor ProSpecTIR-VS.

Os melhores resultados foram obtidos pelo modelo PLSR 2m (EQUAÇÃO (22)) a partir da amostragem de 30 pixels equivalentes a pontos de coleta de amostra nas áreas de plantio de milho, produziu um RMSECV de 1,014 g $kg^{-1}$ (FIGURA 49-B).

Figura 48 - Valores observados e previstos da concentração de N foliar (g $kg^{-1}$) dos modelos PLSR, para os conjuntos de dados de reflectância 1m (A) (n=36), 2m (B) (n=30) e todos os dados (n=66) (C). O coeficiente de determinação ($R^2$), erro quadrado médio da calibração (RMSEC) e validação cruzada (RMSECV) e valores preditivos residuais (RPD), respectivamente

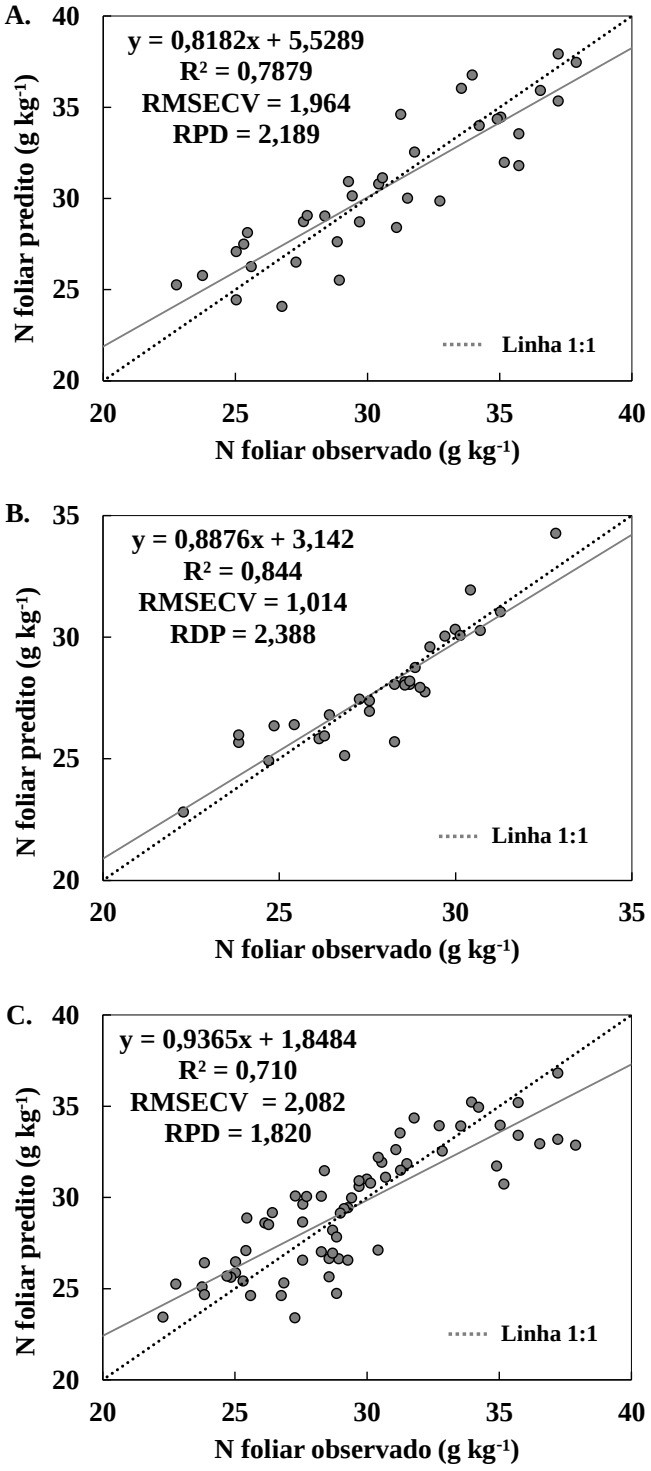


Fonte: elaboração do autor.

Figura 49 - Concentração de N foliar (g $Kg^{-1}$) estimados para áreas de cultivo de milho na imagem hiperespectral ProSpecTIR-VS, com base nos modelos PLSR calibrados para: A) estádio vegetativo (1m) e B) estádio reprodutivo (2m)

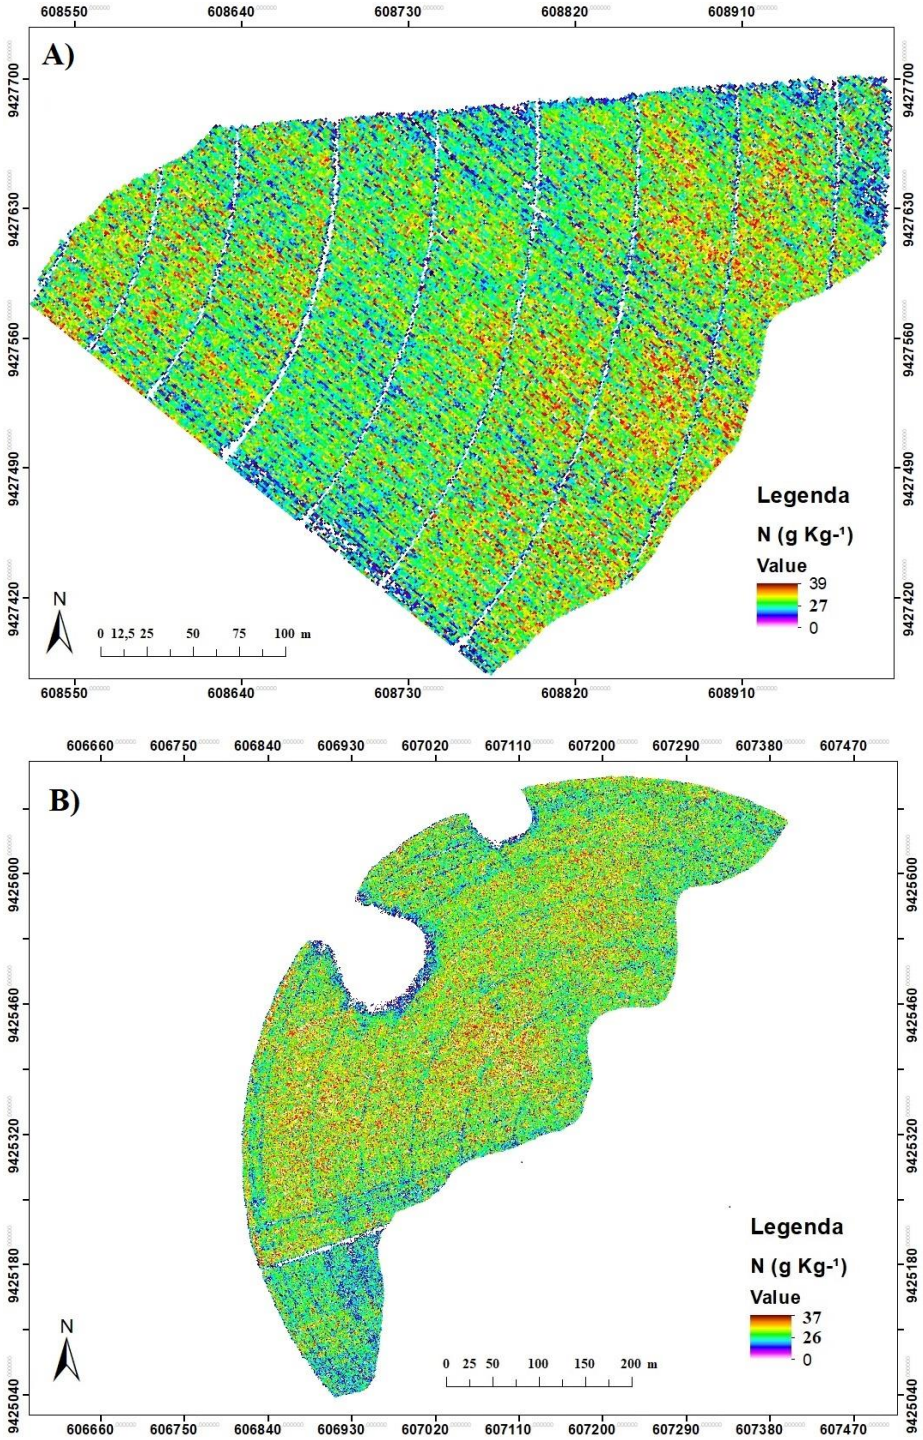


Fonte: elaboração do autor.

Figura 50 - Concentração de N foliar (g $Kg^{-1}$) estimados para áreas de cultivo de milho na imagem hiperespectral ProSpecTIR-VS, com base no modelo misto (1m+2m) PLSR calibrados aplicado nas áreas: A) estádio vegetativo e B) estádio reprodutivo

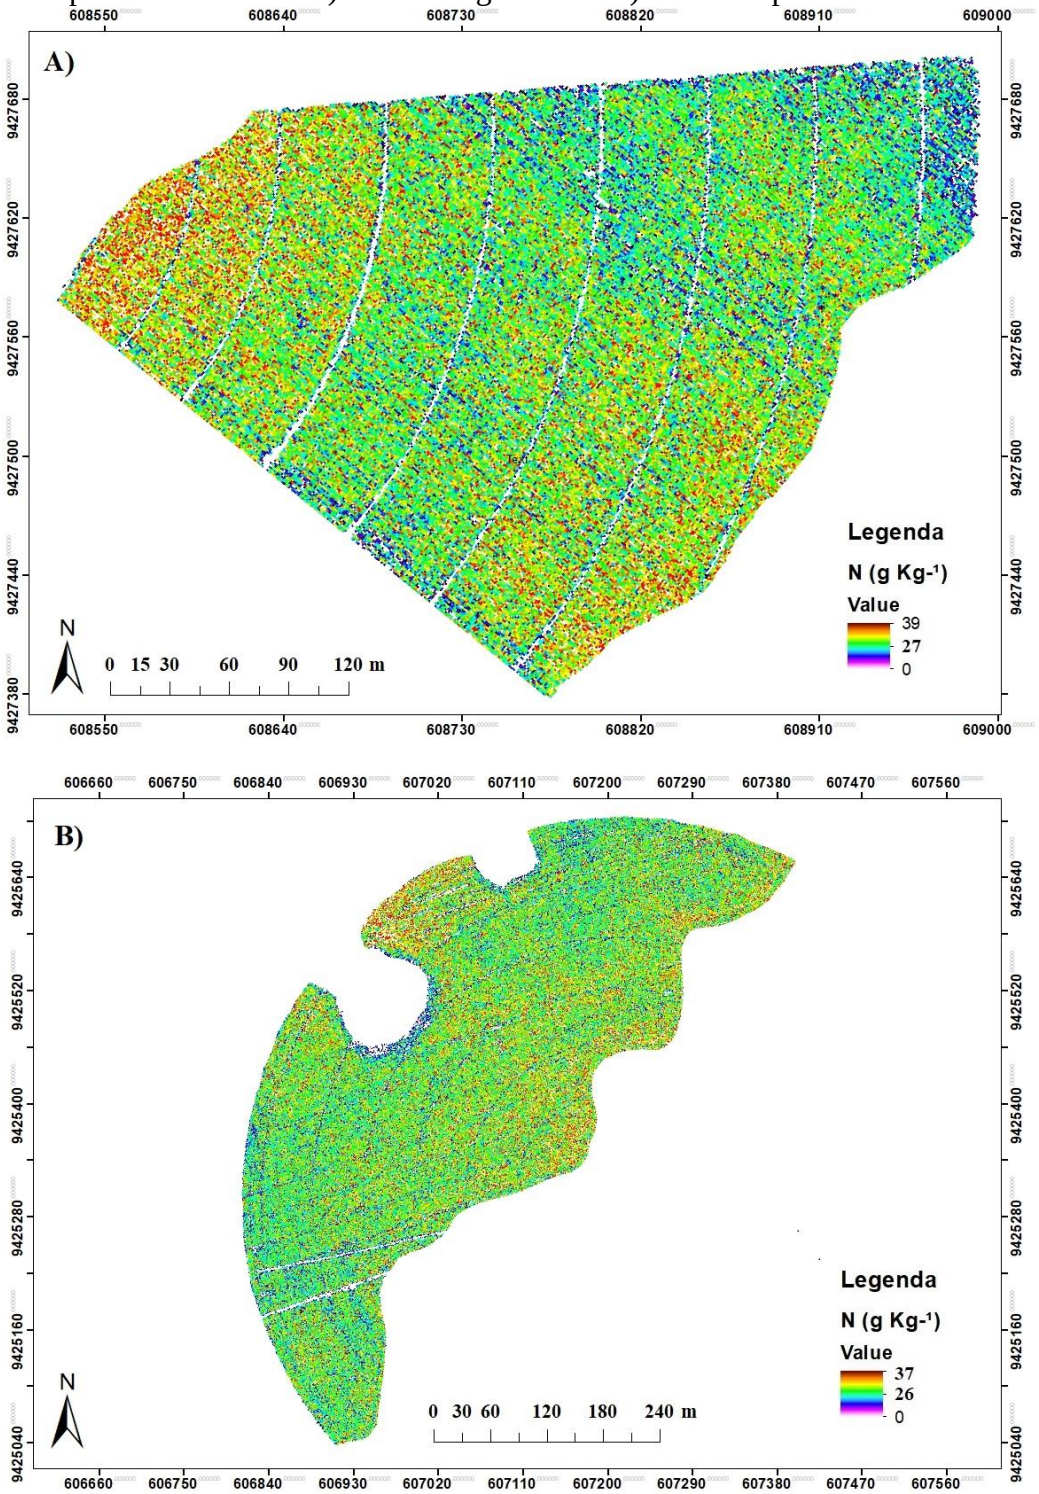


Fonte: elaboração do autor.

## Discussão

### *Bandas selecionadas pelo método stepwise*

Os comprimentos de onda selecionados para estimar N foliar são mostrados na Tabela 15. Foi selecionada uma ampla gama de bandas espectrais diferentes entre os três conjuntos de dados. As faixas localizadas entre 450 nm e 880 nm foram dominantes nos modelos 1m e 2m, enquanto que no modelo como todos os dados prevaleceram bandas centradas entre 1400 nm e 2400 nm.

A maioria das faixas de comprimentos de onda considerados importantes foram selecionados em regiões conhecidas de resposta de absorção de constituintes bioquímicos na vegetação. Para predição do N foliar foram incluídas faixas do VIS (450 nm a 700 nm), que tiveram enorme peso na calibração dos modelos. Essas bandas são altamente correlacionadas com a concentração de clorofila nas folhas (MIPHOKASAP *et al.,* 2012). As faixas no NIR (700 nm a 880 nm) incluídas nos modelos estão associadas, além de constituintes bioquímicos, a mudanças na estrutura da vegetação. Bandas localizadas nessas faixas são sensíveis a concentração de nitrogênio (SCHLEMMER *et al.,* 2013; RAMOELO *et al.,* 2014). Em todos os modelos, foram selecionadas bandas em comum próximas a 670 nm. Essa faixa especifica corresponde a característica máxima absorção da clorofila-a e que não são obscurecidos por outros pigmentos bioquímicos da folha (FEILHAUER *et al.,* 2015).

Os coeficientes de regressão para todas as regiões sensíveis obtidas para os dois modelos (1m e 2m) foram variadas em comparação com o modelo com todos os dados. A diferença na inclusão de diferentes bandas no VIS e no NIR entre os modelos teve forte influência do estádio fenológico. Mudanças sazonais na arquitetura do dossel, estrutura foliar e conteúdo de clorofila foliar, bem como mudanças na influência de efeitos de fundo, são as principais características que alteram a reflectância entre estádios (PENG *et al.,* 2017).

As feições de absorção próximas a 1410,8 nm e 1498,48 nm, observadas na modelagem de todos os dados juntos (TABELA 15), são atribuídas a variação do conteúdo de água na vegetação (CAO *et al.,* 2015). A contribuição dessas faixas foi mais relevante para a calibração quando a análise foi realizada com todos os dados conjuntamente. Dessa forma, a mudança na composição estrutural em função dos estádios de desenvolvimento, incluindo conteúdo de água na folha, podem ter influenciado para a calibração. A influência das propriedades estruturais nos comprimentos de onda relacionados a resposta de água foram

relatadas em estudos anteriores a partir de um conjunto de variadas espécies (FEILHAUER *et al.*, 2015). As características de absorção em torno de 1400 nm encontradas, coincidem com bandas de alta sensibilidade e poder de predição da variação do conteúdo relativo de água na folha (DAS *et al.*, 2017).

Para os três modelos preditivos, a região entre 2300 nm e 2450 apresentou considerável importância para seleção de variáveis. Essa faixa está associada a características de absorção de constituintes da matéria seca das folhas, incluindo lignina, proteínas e celulose (FEILHAUER *et al.*, 2015). Em vários estudos sobre as características espectrais de constituintes bioquímicos de folhas, os autores encontram um consenso nas faixas entorno 2300 nm com as de maior relevância na predição dos componentes de interesse da matéria seca. A faixa de 2100 nm e 2300 nm mostrou-se como a mais apropriada para seleção de bandas preditivas relacionadas proteína, celulose e lignina em folhas frescas, independente do conteúdo de água foliar (WANG *et al.*, 2015).

As mudanças ocorridas na profundidade e formas de absorção do espectro em faixas mais elevadas em torno de 2375 nm, também foram relatadas como importantes preditores de matéria seca (RIVARD; SÁNCHEZ-AZOFEIFA, 2011). Dentre os componentes bioquímicos da matéria seca, a lignina tem despertado interesse na maioria das pesquisas. A lignina é um tipo especial de polifenol encontradas nas plantas e associada a celulose na parede celular, relacionado com a rigidez e pode variar dependendo do tecido da planta (TOLBERT *et al.*, 2014). Por apresentar essas características, as regiões das propriedades bioquímicas da matéria seca coincidem com as bandas que apresentam forte correlação como o nitrogênio foliar, em torno de 1510 nm e 2300 nm (DECHANT *et al.*, 2017).

***Avaliação do desempenho dos Modelos PLSR***

Os modelos PLSR produziram resultados diferentes dependendo do conjunto de dados e estádio fenológico da cultura (EQUAÇÃO 21, 22 e 23). Considerando todas as métricas da Tabela 15, o melhor modelo PLSR foi o 2m com bandas de reflectância do sensor ProSpecTIR-VS localizadas em 451,12, 695,8, 792,05, 830,89, 879,7, 2447,97 nm (EQUAÇÃO 22):

$$N_{1m} = 26{,}20 + 1{,}55_{\rho_{643{,}37\ nm}} - 5{,}06_{\rho_{676{,}7\ nm}} - 7{,}93_{\rho_{700{,}59\ nm}} + 6{,}92_{\rho_{787{,}21\ nm}} + 1{,}04_{\rho_{2379{,}32\ nm}}$$

(21)

$$N_{2m} = 24{,}315 + 0{,}465\rho_{451{,}12nm} - 3{,}827\rho_{695{,}8nm} + 0{,}601\rho_{792{,}05nm} - 0{,}447\rho_{830{,}89nm} + 5{,}896\rho_{879{,}7\ nm} \cdots$$

$$- 0{,}249\rho_{2447{,}97\ nm}$$

(22)

$$N_{1m+2m} = 34{,}306 + 14{,}563\rho_{437{,}25nm} - 4{,}290\rho_{441{,}87nm} - 2{,}031\rho_{667{,}16nm} + 5{,}532\rho_{686{,}24nm} \cdots$$

$$- 5{,}461\rho_{1410{,}8\ nm} - 7{,}532\rho_{1498{,}48\ nm} + 3{,}218\rho_{2266{,}88\ nm} - 3{,}198\rho_{2366{,}83\ nm} - 1{,}128\rho_{2398{,}05\ nm}$$

(23)

Verificou-se que nos modelos 1m e 2m, os maiores coeficientes foram correspondentes a comprimentos de onda situados entre faixas da borda vermelha e NIR. As bandas de 700,59 nm e 695,80 nm apresentaram correlações negativas, enquanto que as bandas 787,21 nm e 879,7 nm apresentaram pesos positivos nas equações, para 1m e 2m respectivamente. As bandas de absorção de clorofila tendem a gerar coeficientes negativos em modelos de previsão de N, ao passo que bandas do NIR relacionadas com o crescimento da vegetação e variáveis biofísicas, como área foliar e biomassa, produzem coeficientes positivamente correlacionados.

Estudos na literatura relatam a influência das regiões da borda vermelha na modelagem da concentração de N foliar. Em estudo com várias culturas, incluindo o milho, Clevers e Gitelson (2013) evidenciaram a faixa localizada entre 724 nm e 800 nm como a mais eficientes para descrever alterações no espectro em relação ao N foliar. Quemada *et al*. (2014), em estudos utilizando dados de imagens hiperespectrais na diagnose nutricional do milho, encontraram as bandas 710 nm e 750 nm como indicadas para diferenciação da resposta de N nas plantas. Independente da condição de limitação causada pelas regiões de absorção de outros componentes na folha, como a água, a região especifica entre 700 nm e 800 nm mostra-se altamente responsiva ao N foliar (WANG *et al.*, 2017). Apesar das consideráveis diferenças entre valores unitários de reflectância, os resultados da seleção de bandas obtidos para o VIS e borda vermelha nesse estudo correspondem a faixas encontradas

para outras culturas. Dunn *et al.* (2016), encontraram maiores coeficientes de regressão em torno da banda 738 nm na calibração de modelos preditivos de nitrogênio foliar na cultura do arroz. Para dados de imagens hiperespectrais na cultura do trigo de inverno, Zhou *et al.* (2016), evidenciaram que as bandas localizadas entre 700 nm e 750 nm desempenharam papel critico na estimativa do conteúdo tanto de N como de clorofila na folha, especialmente a banda 705 nm. Segundo Miphokasap et al., (2012), a importância dos comprimentos de onda situados entre 700 nm e 750 nm na estimativa de N foliar está relacionado ao fato dessa região ser o ponto crítico na borda vermelha em torno do qual ocorrem mudanças na máxima inclinação dos espectros de reflectância em função de variações do conteúdo de constituintes bioquímicos.

No modelo misto, foram selecionadas bandas em diferentes regiões do espectro. Nesse conjunto de dados, pode ter havido maior influência de fatores como características estruturais, mudanças de biomassa e de área foliar, em relação aos conjuntos individuais, por se tratar de um banco de dados que incluem plantas de diferentes estádios de desenvolvimento. No entanto, as faixas selecionadas no modelo misto coincidem com regiões de importância predição de N foliar em outras culturas. Em estudo na cultura do trigo, foram encontradas bandas relacionadas como a concentração de N foliar no VIS, principalmente na região azul (440 a 501 nm) verde (573 - 586 nm), sendo essas, caracterizadas por uma forte absorção de luz devido a clorofilas a e b (HANSEN; SCHJOERRING, 2003). Segundo Ecarnot *et al.* (2013), a resposta em função do N foliar pode ser observada ao longo do espectro em diferentes regiões como entre (450 nm – 750 nm) devido a clorofila, e (2000 - 2300) devido a proteínas do mesófilo. No entanto, Yuan *et al.* (2016), sugerem a região entre 1500 - 2400 nm como a mais indicada para seleção de bandas relacionadas a concentração de N foliar na cultura do milho. Segundo os mesmos autores, a importância dessa região deve-se à influência das ligações N-H em proteínas que sobressaem sobre a resposta de pigmentos no VIS.

Com relação ao ajuste dos dados à linha de regressão, os modelos apresentaram diferentes resultados. No modelo 2m, verificou-se que o declive da linha de regressão foi diminuído principalmente, pela subestimação de valores de N entre 23 e 25 g $kg^{-1}$ e superestimação de algumas amostras entre 26 e 29 g $kg^{-1}$ (FIGURA 48-B). Nos modelos 1m e misto, as previsões da concentração de N variaram consistentemente em torno da Linha 1: 1 (FIGURAS 48-A E 48-C). Esses resultados indicaram que a previsão do N foliar foi afetada pelo conjunto de dados usado. As diferenças no desempenho estão associadas,

principalmente, a fatores como tipo de coleta de dados, diluição do N foliar e mudanças de biomassa durante o ciclo de desenvolvimento da cultura (FENG *et al.*, 2016; XIA *et al.*, 2016). Os melhores desempenhos no estádio reprodutivo (2m), estão de acordo com achados por Quemada *et al.* (2014), que obtiveram resultados mais precisos de índices de vegetação relacionados ao nitrogênio no estádio reprodutivo da cultura milho.

As previsões da concentração de nitrogênio foliar nesse estudo alcançaram níveis de precisão com RPD entre 1,820 a 2,388, dependendo do conjunto de dados utilizado. Quando utilizado todos os dados, obteve-se menor RPD e RMSECV mais alto em relação a modelagem individual (FIGURA 48).

Os resultados de predição de nitrogênio foliar obtidos nesse estudo para o melhor modelo 2m ($R^2$ = 0,84, RMSE = 9,5% do range e RPD =2,388), foram similares aos encontrados por Wang *et al.* (2017), a partir de dados de reflectância coletados em condições de laboratório, no qual atingiu $R^2$ = 0,83 e RMSE = 11% do range. O modelo 2m produziu desempenho superior aos achados por Zhai *et al.* (2013), que desenvolveram um modelo PLSR a partir de dados de diversas culturas agrícolas, incluindo o milho ($R^2$ = 0,663, RMSEv = 12,5 % do range e RPD =1,75). Nesse caso, a combinação das diversas culturas dificultou o ajuste do N foliar com os espectros de reflectância. Ainda para modelos a partir de dados de laboratório, Yuan *et al.* (2016), utilizaram estratégias para encontra o melhor range de bandas a partir de sua importância para estimar N foliar em milho doce, ao invés de bandas únicas. Dessa forma, encontraram a faixa 1500 nm a 2400 nm como a mais indicada para os modelos PLSR, conseguindo atingir $R^2$ = 0,90 e RMSE = 5,75% do range para validação cruzada.

Quanto a aplicação de dados de imagens hipersepctrais, os resultados de modelos PLSR apresentam melhor desempenho em relação a métodos de estimativas por meio de índices de vegetação encontrados na literatura. Cilia *et al.* (2014), a partir de imagens do sensor AISA Eagle de cultivos de milho com fertilização variada de N (0 - 100 kg $ha^{-1}$), testaram o desempenho de índices na faixa entre 394 nm e 968 mm e atingiram a performance máxima de R= 0,70, na estimativa do N foliar. Em trabalho semelhante, Quemada *et al.* (2014) testaram dados do sensor imageador Micro-Hyperspec VNIR, que opera na faixa entre 400 nm e 885 nm, na estimativa de N foliar por meio de índices de vegetação e alcançaram o máximo resultado com r=0,61, utilizando a relação entre as bandas 750 nm e 710 nm. Recentemente, imagens coletadas por sensores hiperespectrais a altitude de 330 m tem apresentado resultados satisfatórios para obtenção de características bioquímicas relacionadas ao status de N foliar (clorofila, flavonoides), e com desempenho variado ($R^2$ entre 0,54 e 0,79)

(GABRIEL *et al.*, 2017). Esses resultados fornecem informações úteis para a avaliação do estado nutricional do milho.

Tanto o tamanho do conjunto de dados (resolução espectral) como o método empregado para a modelagem de parâmetros bioquímicos na vegetação influência no resultado final. Diversos trabalhos relatam que a previsão baseada em PLSR pode melhorar os resultados extraindo o máximo de informações latentes e alternativamente contornados problemas de homogeneidade dos dados (ATZBERGER *et al.*, 2010; RUY *et al.*, 2011). Salientamos que este estudo foi realizado em conjuntos de dados de amostras heterogêneas, obtidos em diferentes estádios de desenvolvimento do milho. Os resultados encontrados podem ser considerados similares ou superiores em comparação a outros trabalhos encontrados na literatura, como citado anteriormente. Parte deste, deve-se a adequação do PLSR na modelagem de dados heterogêneos gerados a partir de coleta de dados em sítios diferentes ou causados por alterações no crescimento vegetal dentro de uma mesma cultura (RUY *et al.*, 2011). Em contraste com IVs, a espectroscopia de reflectância combinada com PLSR pode extrair informações sensíveis do espectro completo, aumentando a precisão das estimativas (YUAN *et al.*, 2016). Além disso, nesse estudo a aplicação da seleção de bandas junto a PLSR contribuíram para melhoria dos resultados. Esses resultados são relatados em estudos anteriores que mostram que o desempenho de modelos PLSR pode ser melhorado através da seleção de banda (KAWAMURA *et al.*, 2017).

As maiores contribuições desse trabalho incluem, a possibilidade da identificação de comprimentos de ondas importantes e redução de conjunto de dados potencialmente relacionados a estimativa da concentração de N foliar na cultura do milho, utilizando o método stepwise em conjunto com o PLSR. Visto a grande complexidade do tratamento e processamento de dados hiperespectrais, os resultados gerados são relevantes para facilitar análise de espectros desses tipos de imagens. O recente desenvolvimento comercial de veículos não tripulados integrados como sistemas de imagens hiperspectral abre a possibilidade de projetar um instrumento preciso e barato para detecção proximal de dados de reflectância espectral, como o objetivo de avaliar o estado nutricional na cultura do milho, reduzindo a necessidade das coletas tradicionais de campo e análise de laboratório.

**Conclusões**

Os resultados indicam que o N foliar pode ser precisamente estimado pelo PLSR utilizando dados do estádio reprodutivo ($R^2$= 0,844, RMSECV= 1,0114 e RPD = 2,388). O modelo misto estimado com dados de diferentes estádios de desenvolvimento é menos preciso em relação aos modelos invidiais. O Uso da PLSR com seleção de bandas do espectro de reflectância é promissor para detecção de N foliar na cultura do milho. A seleção de bandas importantes para a explicação do N foliar extrai o máximo de informações latentes em um conjunto reduzido de dados, e dessa forma, aumenta a capacidade preditiva.

# REFERÊNCIAS


ADNAN, A.; HÖRSTEN, D. V.; PAWELZIK, E.; MÖRLEIN, D. Rapid Prediction of Moisture Content in Intact Green Coffee Beans Using Near Infrared Spectroscopy. **Foods**, v. 6, n. 5, p. 38, 2017.

ANDERSEN, C. M.; BRO, R. Variable selection in regression—a tutorial. **Journal of Chemometrics**, v. 24, n. 11-12, p. 728-737, 2010.

ATZBERGER, C.; GUÉRIF, M.; BARET, F.; WERNER, W. Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat. **Computers and Electronics in Agriculture**, v. 73, n. 2, p. 165-173, 2010.

CAO, Z.; WANG, Q.; ZHENG, C. Best hyperspectral indices for tracing leaf water status as determined from leaf dehydration experiments. **Ecological indicators**, v. 54, p. 96-107, 2015.

CHENG, T.; RIVARD, B.; SANCHEZ-AZOFEIFA, A. Spectroscopic determination of leaf water content using continuous wavelet analysis. **Remote Sensing of Environment**, v. 115, n. 2, p. 659-670, 2011.

CILIA, C.; PANIGADA, C.; ROSSINI, M.; MERONI, M.; BUSETTO, L.; AMADUCCI, S.; COLOMBO, R. Nitrogen status assessment for variable rate fertilization in maize through hyperspectral imagery. **Remote Sensing**, v. 6, n. 7, p. 6549-6565, 2014

CILIA, C.; PANIGADA, C.; ROSSINI, M.; MERONI, M.; BUSETTO, L.; AMADUCCI, S.; COLOMBO, R. Nitrogen status assessment for variable rate fertilization in maize through hyperspectral imagery. **Remote Sensing**, v. 6, n. 7, p. 6549-6565, 2014.

CLEVERS, J. G. P. W.; GITELSON, A. A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and-3. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 344-351, 2013.

D'ACQUI, L. P.; PUCCI, A.; JANIK, L. J. Soil properties prediction of western Mediterranean islands with similar climatic environments by means of mid-infrared diffuse reflectance spectroscopy. **European journal of soil science**, v. 61, n. 6, p. 865-876, 2010.

DAS, B.; SAHOO, R. N.; PARGAL, S.; KRISHNA, G.; VERMA, R.; CHINNUSAMY, V.; GUPTA, V. K. Comparison of different uni-and multi-variate techniques for monitoring leaf water status as an indicator of water-deficit stress in wheat through spectroscopy. **Biosystems Engineering**, v. 160, p. 69-83, 2017.

DECHANT, B.; CUNTZ, M.; VOHLAND, M.; SCHULZ, E.; DOKTOR, D. Estimation of photosynthesis traits from leaf reflectance spectra: Correlation to nitrogen content as the dominant mechanism. **Remote sensing of environment**, v. 196, p. 279-292, 2017.

DEPARTAMENTO NACIONAL DE OBRAS CONTRA AS SECAS – DNOCS. Perímetro Irrigado Jaguaribe-Apodi. Disponível em: < http://www.dnocs.gov.br/~dnocs/doc/canais/perimetros_irrigados/ce/jaguaribe_apodi.html>. Acesso em: 20 Abr. 2016.

DUNN, B. W.; DEHAAN, R.; SCHMIDTKE, L. M.; DUNN, T. S.; MEDER, R. Using field-derived hyperspectral reflectance measurement to identify the essential wavelengths for

predicting nitrogen uptake of rice at panicle initiation. **Journal of Near Infrared Spectroscopy**, v. 24, n. 5, p. 473-483, 2016.

ECARNOT, M.; COMPAN, F.; ROUMET, P. Assessing leaf nitrogen content and leaf mass per unit area of wheat in the field throughout plant cycle with a portable spectrometer. **Field Crops Research**, v. 140, p. 44-50, 2013.

FEILHAUER, H.; ASNER, G. P.; MARTIN, R. E. Multi-method ensemble selection of spectral bands related to leaf biochemistry. **Remote Sensing of Environment**, v. 164, p. 57-65, 2015.

FENG, W.; ZHANG, H. Y.; ZHANG, Y. S.; QI, S. L.; HENG, Y. R.; GUO, B. B.; GUO, T. C. Remote detection of canopy leaf nitrogen concentration in winter wheat by using water resistance vegetation indices from in-situ hyperspectral data. **Field Crops Research**, v. 198, p. 238-246, 2016.

GABRIEL, J. L.; ZARCO-TEJADA, P. J.; LÓPEZ-HERRERA, P. J.; PÉREZ-MARTÍN, E.; ALONSO-AYUSO, M.; QUEMADA, M. Airborne and ground level sensors for monitoring nitrogen status in a maize crop. **Biosystems engineering**, v. 160, p. 124-133, 2017.

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**, v. 86, n. 4, p. 542-553, 2003.

INOUE, Y., SAKAIYA, E., ZHU, Y., & TAKAHASHI, W. Diagnostic mapping of canopy nitrogen content in rice based on hyperspectral measurements. **Remote Sensing of Environment**, v. 126, p. 210-221, 2012.

JIA, X.; SHAO, L.; LIU, P.; ZHAO, B.; GU, L.; DONG, S.; ZHAO, B. Effect of different nitrogen and irrigation treatments on yield and nitrate leaching of summer maize (*Zea mays* L.) under lysimeter conditions. **Agricultural Water Management**, v. 137, p. 92-103, 2014.

KAWAMURA, K.; TSUJIMOTO, Y.; RABENARIVO, M.; ASAI, H.; ANDRIAMANANJARA, A.; RAKOTOSON, T. Vis-NIR Spectroscopy and PLS Regression with Waveband Selection for Estimating the Total C and N of Paddy Soils in Madagascar. **Remote Sensing**, v. 9, n. 10, p. 1081, 2017.

LENKA, S.; SINGH, A. K.; LENKA, N. K. Soil water and nitrogen interaction effect on residual soil nitrate and crop nitrogen recovery under maize–wheat cropping system in the semi-arid region of northern India. **Agriculture, ecosystems & environment**, v. 179, p. 108-115, 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.

MUÑOZ-HUERTA, R. F.; GUEVARA-GONZALEZ, R. G.; CONTRERAS-MEDINA, L. M.; TORRES-PACHECO, I.; PRADO-OLIVAREZ, J.; OCAMPO-VELAZQUEZ, R. V. A review of methods for sensing the nitrogen status in plants: advantages, disadvantages and recent advances. **Sensors**, v. 13, n. 8, p. 10823-10843, 2013.

PENG, Y.; GITELSON, A. A. Remote estimation of gross primary productivity in soybean and maize based on total crop chlorophyll content. **Remote Sensing of Environment**, v. 117, p. 440-448, 2012.

PENG, Y.; NGUY-ROBERTSON, A.; ARKEBAUER, T.; GITELSON, A. A. Assessment of canopy chlorophyll content retrieval in maize and soybean: Implications of hysteresis on the development of generic algorithms. **Remote Sensing**, v. 9, n. 3, p. 226, 2017.

PIRES, M. V.; DA CUNHA, D. A.; DE MATOS CARLOS, S.; COSTA, M. H. Nitrogen-use efficiency, nitrous oxide emissions, and cereal production in Brazil: current trends and forecasts. **PloS one**, v. 10, n. 8, p. e0135234, 2015.

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

RAMOELO, A.; SKIDMORE, A. K.; CHO, M. A.; SCHLERF, M.; MATHIEU, R.; HEITKÖNIG, I. M. Regional estimation of savanna grass nitrogen using the red-edge band of the spaceborne RapidEye sensor. **International Journal of Applied Earth Observation and Geoinformation**, v. 19, p. 151-162, 2012.

RYU, C.; SUGURI, M.; UMEDA, M. Multivariate analysis of nitrogen content for rice at the heading stage using reflectance of airborne hyperspectral remote sensing. **Field Crops Research**, v. 122, n. 3, p. 214-224, 2011.

SCHLEMMER, M.; GITELSON, A.; SCHEPERS, J.; FERGUSON, R.; PENG, Y.; SHANAHAN, J.; RUNDQUIST, D. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. **International Journal of Applied Earth Observation and Geoinformation**, v. 25, p. 47-54, 2013.

SHARMA, L. K.; BU, H.; DENTON, A.; FRANZEN, D. W. Active-optical sensors using red NDVI compared to red edge NDVI for Prediction of corn grain yield in North Dakota, USA. **Sensors**, v. 15, n. 11, p. 27832-27853, 2015.

SHI, T.; WANG, J.; LIU, H.; WU, G. Estimating leaf nitrogen concentration in heterogeneous crop plants from hyperspectral reflectance. **International Journal of Remote Sensing**, v. 36, n. 18, p. 4652-4667, 2015.

TOLBERT, A.; AKINOSHO, H.; KHUNSUPAT, R.; NASKAR, A. K.; RAGAUSKAS, A. J. Characterization and analysis of the molecular weight of lignin for biorefining studies. **Biofuels, Bioproducts and Biorefining**, v. 8, n. 6, p. 836-856, 2014.

TRACHSEL, S.; SAN VICENTE, F. M.; SUAREZ, E. A.; RODRIGUEZ, C. S.; ATLIN, G. N. Effects of planting density and nitrogen fertilization level on grain yield and harvest index in seven modern tropical maize hybrids (*Zea mays* L.). **The Journal of Agricultural Science**, v. 154, n. 4, p. 689-704, 2016.

WANG, B. J.; CHEN, J. M.; JU, W.; QIU, F.; ZHANG, Q.; FANG, M.; CHEN, F. Limited Effects of Water Absorption on Reducing the Accuracy of Leaf Nitrogen Estimation. **Remote Sensing**, v. 9, n. 3, p. 291, 2017.

WANG, Z.; SKIDMORE, A. K.; WANG, T.; DARVISHZADEH, R.; HEARNE, J. Applicability of the PROSPECT model for estimating protein and cellulose+ lignin in fresh leaves. **Remote sensing of environment**, v. 168, p. 205-218, 2015.

WEI, S.; WANG, X.; SHI, D.; LI, Y.; ZHANG, J.; LIU, P.; DONG, S. The mechanisms of low nitrogen induced weakened photosynthesis in summer maize (*Zea mays* L.) under field conditions. **Plant Physiology and Biochemistry**, v. 105, p. 118-128, 2016.

XIA, T.; MIAO, Y.; WU, D.; SHAO, H.; KHOSLA, R.; MI, G. Active optical sensing of spring maize for in-season diagnosis of nitrogen status based on nitrogen nutrition index. **Remote Sensing**, v. 8, n. 7, p. 605, 2016.

YUAN, M.; COUTURE, J. J.; TOWNSEND, P. A.; RUARK, M. D.; BLAND, W. L. Spectroscopic Determination of Leaf Nitrogen Concentration and Mass Per Area in Sweet Corn and Snap Bean. **Agronomy Journal**, v. 108, n. 6, p. 2519-2526, 2016.

ZHAI, Y.; CUI, L.; ZHOU, X.; GAO, Y.; FEI, T.; GAO, W. Estimation of nitrogen, phosphorus, and potassium contents in the leaves of different plants using laboratory-based visible and near-infrared reflectance spectroscopy: comparison of partial least-square regression and support vector machine regression methods. **International journal of remote sensing**, v. 34, n. 7, p. 2502-2518, 2013.

ZHOU, X.; HUANG, W.; KONG, W.; YE, H.; LUO, J.; CHEN, P. Remote estimation of canopy nitrogen content in winter wheat using airborne hyperspectral reflectance measurements. **Advances in Space Research**, v. 58, n. 9, p. 1627-1637, 2016.

# 7 CONSIDERAÇÕES FINAIS

O presente estudo investigou o potencial de aplicação dos dados de sensoriamento remoto para diagnóstico nutricional na cultura do milho irrigado.

A análise dos componentes de produção mostrou que os tratamentos de lâminas de irrigação e adubação nitrogenada afetam a eficiência do uso da água e do nitrogênio nas plantas, e consequentemente, refletem na produtividade e crescimento da cultura. Diante desses resultados, conclui-se que o manejo adequado da irrigação baseado na manutenção adequada da umidade do solo, somada ao gerenciamento da aplicação de fertilizantes nitrogenados com base em demandas locais, é fundamental para melhorar a eficiência do uso recursos, proporcionando ganhos em produtividade e reduzindo potenciais riscos ambientais. Nesse sentido, técnicas de diagnose nutricional por meio de dados de sensoriamento remoto mostram-se promissoras para o manejo da adubação.

A caracterização espectral das plantas nos níveis de dossel e de folha, feitas em campo e laboratório, respectivamente, mostrou que as regiões do espectro mais sensíveis as concentrações de N foliar estão localizadas principalmente no visível na faixa entre 400 nm a 700 nm e no infravermelho próximo entre 800 nm a 1300 nm. O nível de coleta de dados é um importante fator que influência no fator de reflectância observado em função dos tratamentos de adubação. Em laboratório, as regiões entre 450 nm -750 nm, mostram-se mais importantes e em nível de campo a melhor resposta pode ser observada entre 800 nm e 1300 nm. A análise derivativa é uma técnica que pode ser utilizada para evidenciar faixas espectrais relevantes para o N foliar. A primeira derivada identificou maiores variações em torno de duas regiões específicas 470 nm a 550 nm e 720 nm a 750 nm. A derivada de segunda ordem, por sua vez, conseguiu evidenciar a faixa coincidente com a resposta de pigmentos de clorofila entre 700 nm e 725 nm.

Em outra forma de análise da dinâmica da reflectância espectral, a técnica de componentes principais mostra ser uma ferramenta útil para análise detalha do espectro de reflctância. Cerca de 90% e 95,12% do total da variação nos espectros pode ser explica utilizando três componentes principais, dependendo do conjunto de dados. Os diferentes tipos de informações encontrados nos conjuntos de dados de laboratório e campo, interferem nos fatores de explicação. Para dados de campo (dossel) o poder refletor ao longo de todo o espectro dominou a componente de maior relevância, ou seja, a de maior poder de explicação (PC1). Para dados de laboratório (folha), a mesma componente sofre influência

principalmente na faixa da borda vermelha (por volta de 700 nm) e ao longo de todo o infravermelho e parte do SWIR (750 nm a 2500 nm). A PC2 para os conjuntos de dados é distinguida principalmente entre as faixas 750 nm a 1300 nm, pelas cargas fatoriais, positivas para nível de folha e negativas para dossel. A PC3 é influenciada no visível, com picos máximos em torno de 550 nm e 750 nm em parte do SWIR em 1800 nm. A identificação das regiões específicas em função dos tratamentos de adubação encontradas, são importantes para mostrar e selecionar faixas de comprimento de onda de interesse para a formulação de índices e modelos preditivos da concentração de N foliar para a cultura do milho.

Dados de sensoriamento remoto obtidos por meio de espectroscopia de reflectância podem ser utilizados para o desenvolvimento de modelos para estimar a concentração de N foliar com sucesso. No entanto, a forma de obtenção de dados influencia no desempenho dos modelos, o que torna necessário o estabelecimento de métodos de coleta bem definidos para alcançar resultados satisfatórios. A modelagem em dados de laboratório tende a ser mais precisa em relação aos obtidos em condições de campo. Além disso, o desempenho varia também em função dos estádios fenológicos da cultura. Os melhores resultados foram obtidos no estádio reprodutivo da cultura. Contudo, visto a importância do manejo da adubação nas fases iniciais de desenvolvimento, a melhoria no estádio vegetativo é um fator importante a ser melhorado.

As estratégias de regressão por mínimos quadrados parcias (PLSR) e razão normalizadas das bandas são estratégias eficientes na modelagem e formulação de índices, respectivamente, para fins de estimativa e quantificação de nitrogênio foliar. As bandas 762 nm e 684 nm são as melhores bandas para a formulação do índice normalizado. Por fim, conclui-se que a modelagem é influenciada pelos estádios fenológicos e pelo nível de coleta de dados, reforçando a importância do ajuste de modelos preditivos em função das diferentes fases de crescimento da cultura.

Os resultados nesse estudo indicam que a quantificação de N na cultura do milho pode ser feita por meio de imagens hiperespectrais. A estimativa da concentração de nitrogênio foliar pode ser precisamente estimada pela metodologia de seleção de comprimentos de onda conjuntamente com regressão por mínimos quadrados parciais (PLRS). A técnica extrai o máximo de informações latentes em um conjunto reduzido de dados, e dessa forma, aumenta a capacidade preditiva. Como comentado anteriormente, o estádio fenológico influência fortemente no desempenho dos modelos gerados. Os melhores resultados são obtidos no estádio reprodutivo. Modelos mistos, formulado a partir de conjunto

de dados de diferentes estádio e locais de coleta diminuem a precisão em relação a modelos individuais. O desenvolvimento de técnicas de diagnose nutricional por meio de dados de sensores remotos é relevante para melhorar a eficiência de programas de manejo de aplicação de fertilizantes, reduzindo a necessidade das coletas tradicionais de campo e análise de laboratório.

# REFRÊNCIAS


ADNAN, A.; HÖRSTEN, D. V.; PAWELZIK, E.; MÖRLEIN, D. Rapid Prediction of Moisture Content in Intact Green Coffee Beans Using Near Infrared Spectroscopy. **Foods**, v. 6, n. 5, p. 38, 2017.

ANDERSEN, C. M.; BRO, R. Variable selection in regression—a tutorial. **Journal of Chemometrics**, v. 24, n. 11-12, p. 728-737, 2010.

ATZBERGER, C.; GUÉRIF, M.; BARET, F.; WERNER, W. Comparative analysis of three chemometric techniques for the spectroradiometric assessment of canopy chlorophyll content in winter wheat. **Computers and Electronics in Agriculture**, v. 73, n. 2, p. 165-173, 2010.

AYDINSAKIR, K.; ERDAL, S.; BUYUKTAS, D.; BASTUG, R.; TOKER, R. The influence of regular deficit irrigation applications on water use, yield, and quality components of two corn (*Zea mays* L.) genotypes. **Agricultural water management**, v. 128, p. 65-71, 2013.

BARROS, José FC; CALADO, José G. **A cultura do milho**. 2014. <http://hdl.handle.net/10174/10804>. Acesso 22 de março de 2018.

BASSO, B.; FIORENTINO, C.; CAMMARANO, D.; SCHULTHESS, U. Variable rate nitrogen fertilizer response in wheat using remote sensing. **Precision agriculture**, v. 17, n. 2, p. 168-182, 2016.

BASTIAANSSEN, W.G.; CHANDRAPALA, L. Water balance variability across Sri Lanka for assessing agricultural and environmental water use. **Agricultural water management**, v. 58, n. 2, p. 171-192, 2003.

BEHMANN, J.; STEINRÜCKEN, J.; PLÜMER, L. Detection of early plant stress responses in hyperspectral images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.93, p.98–111, 2014.

BENEDETTO, D.; CASTRIGNANO, A.; DIACONO, M.; RINALDI, M.; RUGGIERI, S.; TAMBORRINO, R. Field partition by proximal and remote sensing data fusion. **Biosystems Engineering**, v.114, n.4, p.372-383, 2013.

BINDER, D. L.; SANDER, D. H.; WALTERS, D. T. Maize response to time of nitrogen application as affected by level of nitrogen deficiency. **Agronomy Journal**, v. 92, n. 6, p. 1228-1236, 2000.

BRO, R.; SMILDE, A. K. Principal component analysis. **Analytical Methods**, v. 6, n. 9, p. 2812-2831, 2014.

CAKIR, R. Effect of water stress at different development stages on vegetative and reproductive growth of corn. **Field Crops Research**, v. 89, n. 1, p. 1-16, 2004.

CAO, H. X.; ZHANG, Z. B.; XU, P.; CHU, L. Y.; SHAO, H. B.; LU, Z. H.; LIU, J. H. Mutual physiological genetic mechanism of plant high water use efficiency and nutrition use efficiency. Colloids and Surfaces B: **Biointerfaces**, v. 57, n. 1, p. 1-7, 2007.

CAO, Z.; WANG, Q.; ZHENG, C. Best hyperspectral indices for tracing leaf water status as determined from leaf dehydration experiments. **Ecological indicators**, v. 54, p. 96-107, 2015.

CASA, R.; CASTALDI, F.; PASCUCCI, S.; PIGNATTI, S. Chlorophyll estimation in field crops: an assessment of handheld leaf meters and spectral reflectance measurements. **The Journal of Agricultural Science**, v. 153, n. 05, p. 876-890, 2015.

CASAS, A.; RIAÑO, D.; USTIN, S. L.; DENNISON, P.; SALAS, J. Estimation of water-related biochemical and biophysical vegetation properties using multitemporal airborne hyperspectral data and its comparison to MODIS spectral response. **Remote Sensing of Environment**, v.148, p.28-41, 2014.

CHEN, P.; HABOUDANE, D.; TREMBLAY, N.; WANG, J.; VIGNEAULT, P.; LI, B. New spectral indicator assessing the efficiency of crop nitrogen treatment in corn and wheat. **Remote Sensing of Environment**, v.114, p.1987–1997, 2010.

CHENG, T.; RIVARD, B.; SANCHEZ-AZOFEIFA, A. Spectroscopic determination of leaf water content using continuous wavelet analysis. **Remote Sensing of Environment**, v. 115, n. 2, p. 659-670, 2011.

CHILUNDO, M.; JOEL, A.; WESSTRÖM, I.; BRITO, R.; MESSING, I. Effects of reduced irrigation dose and slow release fertiliser on nitrogen use efficiency and crop yield in a semi-arid loamy sand. **Agricultural Water Management**, v. 168, p. 68-77, 2016.

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

CHU, X.; GUO, Y.; HE, J.; YAO, X.; ZHU, Y.; CAO, W.; TIAN, Y. Comparison of different hyperspectral vegetation indices for estimating canopy leaf nitrogen accumulation in rice. **Agronomy Journal**, v. 106, n. 5, p. 1911-1920, 2014.

CILIA, C.; PANIGADA, C.; ROSSINI, M.; MERONI, M.; BUSETTO, L.; AMADUCCI, S.; COLOMBO, R. Nitrogen status assessment for variable rate fertilization in maize through hyperspectral imagery. **Remote Sensing**, v. 6, n. 7, p. 6549-6565, 2014.

CLEVERS, J. G. P. W.; GITELSON, A. A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and-3. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 344-351, 2013.

CONPANHIA NACIONAL DE ABASTECIMENTO**. Acompanhamento da safra brasileira de grãos**, v. 2 - Safra 2014/15, n. 9 - Nono levantamento, Brasília, p. 1-104, junho 2015.

CORTI, M., GALLINA, P. M., CAVALLI, D., & CABASSI, G. Hyperspectral imaging of spinach canopy under combined water and nitrogen stress to estimate biomass, water, and nitrogen content. **Biosystems Engineering**, v. 158, p. 38-50, 2017.

D'ACQUI, L. P.; PUCCI, A.; JANIK, L. J. Soil properties prediction of western Mediterranean islands with similar climatic environments by means of mid-infrared diffuse reflectance spectroscopy. **European journal of soil science**, v. 61, n. 6, p. 865-876, 2010.

DAS, B.; SAHOO, R. N.; PARGAL, S.; KRISHNA, G.; VERMA, R.; CHINNUSAMY, V.; GUPTA, V. K. Comparison of different uni-and multi-variate techniques for monitoring leaf water status as an indicator of water-deficit stress in wheat through spectroscopy. **Biosystems Engineering**, v. 160, p. 69-83, 2017.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; DE COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.

DECHANT, B.; CUNTZ, M.; VOHLAND, M.; SCHULZ, E.; DOKTOR, D. Estimation of photosynthesis traits from leaf reflectance spectra: Correlation to nitrogen content as the dominant mechanism. **Remote sensing of environment**, v. 196, p. 279-292, 2017.

DEPARTAMENTO NACIONAL DE OBRAS CONTRA AS SECAS – DNOCS. Perímetro Irrigado Jaguaribe-Apodi. Disponível em: < http://www.dnocs.gov.br/~dnocs/doc/canais/perimetros_irrigados/ce/jaguaribe_apodi.html>. Acesso em: 20 Abr. 2016.

DI PAOLO, E.; RINALDI, M. Yield response of corn to irrigation and nitrogen fertilization in a Mediterranean environment. **Field Crops Research**, v. 105, n. 3, p. 202-210, 2008.

DIKER, K.; BAUSCH, W. C. Potential use of nitrogen reflectance index to estimate plant parameters and yield of maize. **Biosystems Engineering**, v. 85, n. 4, p. 437-447, 2003.

DJAMAN, K.; IRMAK, S.; MARTIN, D. L.; FERGUSON, R. B.; BERNARDS, M. L. Plant nutrient uptake and soil nutrient dynamics under full and limited irrigation and rainfed maize production. **Agronomy Journal**, v. 105, n. 2, p. 527-538, 2013.

DUNN, B. W.; DEHAAN, R.; SCHMIDTKE, L. M.; DUNN, T. S.; MEDER, R. Using field-derived hyperspectral reflectance measurement to identify the essential wavelengths for predicting nitrogen uptake of rice at panicle initiation. **Journal of Near Infrared Spectroscopy**, v. 24, n. 5, p. 473-483, 2016.

ECARNOT, M.; COMPAN, F.; ROUMET, P. Assessing leaf nitrogen content and leaf mass per unit area of wheat in the field throughout plant cycle with a portable spectrometer. **Field Crops Research**, v. 140, p. 44-50, 2013.

FAO - FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. Statistics Division. 2015. Disponível em: < http://faostat3.fao.org/>. Acesso em: 18 Abr. 2016.

FEILHAUER, H.; ASNER, G. P.; MARTIN, R. E. Multi-method ensemble selection of spectral bands related to leaf biochemistry. **Remote Sensing of Environment**, v. 164, p. 57-65, 2015.

FENG, W.; ZHANG, H. Y.; ZHANG, Y. S.; QI, S. L.; HENG, Y. R.; GUO, B. B.; GUO, T. C. Remote detection of canopy leaf nitrogen concentration in winter wheat by using water resistance vegetation indices from in-situ hyperspectral data. **Field Crops Research**, v. 198, p. 238-246, 2016.

FERNANDES, F. C. S.; BUZETTI, S.; ARF, O.; ANDRADE, J. D. C. Doses, eficiência e uso de nitrogênio por seis cultivares de milho. **Revista Brasileira de Milho e Sorgo**, v. 4, n. 2, p. 195-204, 2005.

FORNASIERI FILHO, Domingos. **Manual da cultura do milho**. Funep, 2007. 576 p.

FRANÇA, S.; MIELNICZUK, J.; ROSA, L. M. G.; BERGAMASCHI, H.; BERGONCI, J. I. Nitrogênio disponível ao milho: Crescimento, absorção e rendimento de grãos. **Revista**

**Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande. Vol. 15, n. 11 (nov. 2011), p. 1143-1151, 2011.

FUHRY, M. **A new tikhonov regularization method**. University Honors. 2011. Tese de doutorado.

GABRIEL, J. L.; ZARCO-TEJADA, P. J.; LÓPEZ-HERRERA, P. J.; PÉREZ-MARTÍN, E.; ALONSO-AYUSO, M.; QUEMADA, M. Airborne and ground level sensors for monitoring nitrogen status in a maize crop. **Biosystems engineering**, v. 160, p. 124-133, 2017.

GHEYSARI, M.; LOESCHER, H. W.; SADEGHI, S. H.; MIRLATIFI, S. M.; ZAREIAN, M. J.; HOOGENBOOM, G. Water-yield relations and water use efficiency of maize under nitrogen fertigation for semiarid environments: experiment and synthesis. In: **Advances in Agronomy**. Academic Press, 2015. p. 175-229.

GHOLAMHOSEINI, M.; AGHAALIKHANI, M.; SANAVY, S. M.; MIRLATIFI, S. M. Interactions of irrigation, weed and nitrogen on corn yield, nitrogen use efficiency and nitrate leaching. **Agricultural water management**, v. 126, p. 9-18, 2013.

GITELSON, A A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote sensing of Environment**, v. 80, n. 1, p. 76-87, 2002.

GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of plant physiology**, v. 160, n. 3, p. 271-282, 2003.

GITELSON, A. A.; PENG, Y.; ARKEBAUER, T. J.; SCHEPERS, J. Relationships between gross primary production, green LAI, and canopy chlorophyll content in maize: Implications for remote sensing of primary production. **Remote Sensing of Environment**, v. 144, p. 65-72, 2014.

GONZALEZ-DUGO, V.; DURAND, J.; GASTAL, F. Water deficit and nitrogen nutrition of crops. A review. **Agronomy for sustainable development**, v. 30, n. 3, p. 529-544, 2010.

GOODIN, D. G.; HAN, L.; FRASER, R. N.; RUNDQUIST, D. C.; STEBBINS, W. A. Analysis of suspended solids in water using remotely sensed high resolution derivative spectra. **Photogrammetric Engineering & Remote Sensing**, v. 59, n. 4, p. 505-510, 1993.

HAN, Luoheng. Estimating chlorophyll-a concentration using first-derivative spectra in coastal water. **International Journal of Remote Sensing**, v. 26, n. 23, p. 5235-5244, 2005.

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**, v. 86, n. 4, p. 542-553, 2003.

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.

HOUBORG, R.; ANDERSON, M.; DAUGHTRY, C.; Utility of an image-based canopy reflectance modeling tool for remote estimation of LAI and leaf chlorophyll content at the field scale. **Remote Sensing of Environment**, v.113, p.259–274, 2009.

HUEMMRICH, K. F. Simulations of seasonal and latitudinal variations in leaf inclination angle distribution: Implications for remote sensing. **Advances in Remote Sensing,** v.2, p.93-101, 2013.

HUNT, E. R.; DORAISWAMY, P. C.; MCMURTREY, J. E.; DAUGHTRY, C. S.; PERRY, E. M.; AKHMEDOV, B. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 103-112, 2013

INOUE, Y., SAKAIYA, E., ZHU, Y., & TAKAHASHI, W. Diagnostic mapping of canopy nitrogen content in rice based on hyperspectral measurements. **Remote Sensing of Environment**, v. 126, p. 210-221, 2012

INOUE, Y.; GUÉRIF, M.; BARET, F.; SKIDMORE, A.; GITELSON, A.; SCHLERF, M.; OLIOSO, A. Simple and robust methods for remote sensing of canopy chlorophyll content: a comparative analysis of hyperspectral data for different types of vegetation. **Plant, cell & environment**, v. 39, n. 12, p. 2609-2623, 2016.

IRMAK, S.; DJAMAN, K.; RUDNICK, D. R. Effect of full and limited irrigation amount and frequency on subsurface drip-irrigated maize evapotranspiration, yield, water use efficiency and yield response factors. **Irrigation science**, v. 34, n. 4, p. 271-286, 2016.

JIA, X.; SHAO, L.; LIU, P.; ZHAO, B.; GU, L.; DONG, S.; ZHAO, B. Effect of different nitrogen and irrigation treatments on yield and nitrate leaching of summer maize (*Zea mays* L.) under lysimeter conditions. **Agricultural Water Management**, v. 137, p. 92-103, 2014.

KAWAMURA, K.; TSUJIMOTO, Y.; RABENARIVO, M.; ASAI, H.; ANDRIAMANANJARA, A.; RAKOTOSON, T. Vis-NIR Spectroscopy and PLS Regression with Waveband Selection for Estimating the Total C and N of Paddy Soils in Madagascar. **Remote Sensing**, v. 9, n. 10, p. 1081, 2017.

KRESOVIĆ, B.; TAPANAROVA, A.; TOMIĆ, Z.; ŽIVOTIĆ, L.; VUJOVIĆ, D.; SREDOJEVIĆ, Z.; GAJIĆ, B. Grain yield and water use efficiency of maize as influenced by different irrigation regimes through sprinkler irrigation under temperate climate. **Agricultural Water Management**, v. 169, p. 34-43, 2016.

LENKA, S.; SINGH, A. K.; LENKA, N. K. Soil water and nitrogen interaction effect on residual soil nitrate and crop nitrogen recovery under maize–wheat cropping system in the semi-arid region of northern India. **Agriculture, ecosystems & environment**, v. 179, p. 108-115, 2013.

LI, F.; MIAO, Y.; FENG, G.; YUAN, F.; YUE, S.; GAO, X.; CHEN, X. Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. **Field Crops Research**, v. 157, p. 111-123, 2014.

LIANG, Shunlin. **Quantitative remote sensing of land surfaces**. John Wiley & Sons, 2005.

LIU, L., SONG, B., ZHANG, S., & LIU, X. A Novel Principal Component Analysis Method for the Reconstruction of Leaf Reflectance Spectra and Retrieval of Leaf Biochemical Contents. **Remote Sensing**, v. 9, n. 11, p. 1113, 2017.

LORENZZETI, J. A. **Princípios físicos de sensoriamento remoto.** São Paulo: Blucher, 2015.

MINOLTA, C. **Manual for chlorophyll meter SPAD-502**. Osaka: Minolta Radiometric Instruments Divisions, 1989.

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.

MIRZAIE, M.; DARVISHZADEH, R.; SHAKIBA, A.; MATKAN, A. A.; ATZBERGER, C.; SKIDMORE, A. Comparative analysis of different uni-and multi-variate methods for estimation of vegetation water content using hyper-spectral measurements. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 1-11, 2014.

MOREIRA, R.C.; GALVÃO, L.S. Variation in spectral shape of urban materials. **Remote Sensing Letters**, v. 01, p. 149-158, mar. 2010.

MUELLER, N. D.; GERBER, J. S.; JOHNSTON, M.; RAY, D. K.; RAMANKUTTY, N.; FOLEY, J. A. Closing yield gaps through nutrient and water management. **Nature**, v. 490, n. 7419, p. 254-257, 2012.

MUNNÉ-BOSCH, S.; ALEGRE, L. Die and let live: leaf senescence contributes to plant survival under drought stress. **Functional Plant Biology**, v.31, n.3, p.203-216, 2004.

MUÑOZ-HUERTA, R. F.; GUEVARA-GONZALEZ, R. G.; CONTRERAS-MEDINA, L. M.; TORRES-PACHECO, I.; PRADO-OLIVAREZ, J.; OCAMPO-VELAZQUEZ, R. V. A review of methods for sensing the nitrogen status in plants: advantages, disadvantages and recent advances. **Sensors**, v. 13, n. 8, p. 10823-10843, 2013.

NAGHETTINI, M.; PINTO, E. J. A. **Correlação e regressão. Hidrologia e Estatística**. Serviço Geológico do Brasil–CPRM, Belo Horizonte, MG, Brasil, 2007.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 4ª ed. São Paulo: Blucher, 2010.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA ALIMENTAÇÃO E AGRICULTURA. Statistics Division. Disponível em: <http://faostat3.fao.org/>. Acesso em: 27 fev. 2018.

PANDEY, R. K.; MARANVILLE, J. W.; & CHETIMA, M. M. Deficit irrigation and nitrogen effects on maize in a Sahelian environment: II. Shoot growth, nitrogen uptake and water extraction. **Agricultural Water Management**, v. 46, n. 1, p. 15-27, 2000.

PENG, J.; FAN, W.; XU, X.; WANG, L.; LIU, Q.; LI, J.; ZHAO, P. Estimating crop albedo in the application of a physical model based on the law of energy conservation and spectral invariants. **Remote Sensing**, v. 7, n. 11, p. 15536-15560, 2015.

PENG, Y.; GITELSON, A. A. Remote estimation of gross primary productivity in soybean and maize based on total crop chlorophyll content. **Remote Sensing of Environment**, v. 117, p. 440-448, 2012.

PENG, Y.; NGUY-ROBERTSON, A.; ARKEBAUER, T.; GITELSON, A. A. Assessment of canopy chlorophyll content retrieval in maize and soybean: Implications of hysteresis on the development of generic algorithms. **Remote Sensing**, v. 9, n. 3, p. 226, 2017.

PEÑUELAS, J.; GAMON, J. A.; FREDEEN, A. L.; MERINO, J.; FIELD, C. B. Reflectance indices associated with physiological changes in nitrogen-and water-limited sunflower leaves. **Remote Sensing of Environment**, v.48, n.2, p.135-146, 1994.

PIRES, M. V.; DA CUNHA, D. A.; DE MATOS CARLOS, S.; COSTA, M. H. Nitrogen-use efficiency, nitrous oxide emissions, and cereal production in Brazil: current trends and forecasts. **PloS one**, v. 10, n. 8, p. e0135234, 2015.

PONZONI, F.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2007.

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

QUEMADA, M.; GABRIEL, J. L. Approaches for increasing nitrogen and water use efficiency simultaneously. **Global Food Security**, v. 9, p. 29-35, 2016.

RAMOELO, A.; SKIDMORE, A. K.; CHO, M. A.; SCHLERF, M.; MATHIEU, R.; HEITKÖNIG, I. M. Regional estimation of savanna grass nitrogen using the red-edge band of the spaceborne RapidEye sensor. **International Journal of Applied Earth Observation and Geoinformation**, v. 19, p. 151-162, 2012.

RITCHIE, Steven W.; HANWAY, John J.; BENSON, Garren O. Como a planta de milho se desenvolve. **Informações agronômicas**, v. 103, p. 1-19, 2003.

RYU, C.; SUGURI, M.; UMEDA, M. Multivariate analysis of nitrogen content for rice at the heading stage using reflectance of airborne hyperspectral remote sensing. **Field Crops Research**, v. 122, n. 3, p. 214-224, 2011.

SAHOO, R. N.; RAY, S. S.; MANJUNATH, K. R. Hyperspectral remote sensing of agriculture. **Current Science**, v. 108, n. 5, p. 848-859, 2015.

SCHLEMMER, M.; GITELSON, A.; SCHEPERS, J.; FERGUSON, R.; PENG, Y.; SHANAHAN, J.; RUNDQUIST, D. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. **International Journal of Applied Earth Observation and Geoinformation**, v. 25, p. 47-54, 2013.

SHARMA, L. K.; BU, H.; DENTON, A.; FRANZEN, D. W. Active-optical sensors using red NDVI compared to red edge NDVI for Prediction of corn grain yield in North Dakota, USA. **Sensors**, v. 15, n. 11, p. 27832-27853, 2015.

SHAVER, T. M.; KHOSLA, R.; WESTFALL, D. G. Evaluation of two crop canopy sensors for nitrogen variability determination in irrigated maize. **Precision Agriculture**, v. 12, n. 6, p. 892-904, 2011.

SHI, T.; WANG, J.; LIU, H.; WU, G. Estimating leaf nitrogen concentration in heterogeneous crop plants from hyperspectral reflectance. **International Journal of Remote Sensing**, v. 36, n. 18, p. 4652-4667, 2015.

SUN, J., YANG, J., SHI, S., CHEN, B., DU, L., GONG, W., & SONG, S. Estimating Rice Leaf Nitrogen Concentration: Influence of Regression Algorithms Based on Passive and Active Leaf Reflectance. **Remote Sensing**, v. 9, n. 9, p. 951, 2017.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. 5. ed. Porto Alegre: Artmed, 2013. 918p.

TEIXEIRA, E. I., GEORGE, M., HERREMAN, T., BROWN, H., FLETCHER, A., CHAKWIZIRA, E.; NOBLE, A. The impact of water and nitrogen limitation on maize biomass and resource-use efficiencies for radiation, water and nitrogen. **Field Crops Research**, v. 168, p. 109-118, 2014.

TOBIAS, Randall D. *et al.* An introduction to partial least squares regression**.** In: **Proceedings of the twentieth annual SAS users group international conference**. SAS Institute Inc. Cary, NC, 1995. p. 1250-1257.

TOLBERT, A.; AKINOSHO, H.; KHUNSUPAT, R.; NASKAR, A. K.; RAGAUSKAS, A. J. Characterization and analysis of the molecular weight of lignin for biorefining studies. **Biofuels, Bioproducts and Biorefining**, v. 8, n. 6, p. 836-856, 2014.

TRACHSEL, S.; SAN VICENTE, F. M.; SUAREZ, E. A.; RODRIGUEZ, C. S.; ATLIN, G. N. Effects of planting density and nitrogen fertilization level on grain yield and harvest index in seven modern tropical maize hybrids (*Zea mays* L.). **The Journal of Agricultural Science**, v. 154, n. 4, p. 689-704, 2016.

TSAI, F.; PHILPOT, W.; Derivative analysis of hyperspectral data. **Remote Sensing of Environment**, v. 66, n. 1, p. 41-51, 1998.

VALERO, J. D. J.; MATURANO, M.; RAMÍREZ, A. A.; MARTÍN-BENITO, J. T.; ÁLVAREZ, J. O. Growth and nitrogen use efficiency of irrigated maize in a semiarid region as affected by nitrogen fertilization. **Spanish Journal of Agricultural Research**, v. 3, n. 1, p. 134-144, 2005.

VON PINHO, R. G.; BORGES, I. D.; PEREIRA, J. L. D. A. R.; DOS REIS, M. C. Marcha de absorção de macronutrientes e acúmulo de matéria seca em milho. **Revista Brasileira de Milho e Sorgo**, v. 8, n. 02, 2010.

WANG, B. J.; CHEN, J. M.; JU, W.; QIU, F.; ZHANG, Q.; FANG, M.; CHEN, F. Limited Effects of Water Absorption on Reducing the Accuracy of Leaf Nitrogen Estimation. **Remote Sensing**, v. 9, n. 3, p. 291, 2017.

WANG, L.; WEI, Y. Revised normalized difference nitrogen index (NDNI) for estimating canopy nitrogen concentration in wetlands. **Optik-International Journal for Light and Electron Optics**, v. 127, n. 19, p. 7676-7688, 2016.

WANG, Y.; JANZ, B.; ENGEDAL, T.; NEERGAARD, A. Effect of irrigation regimes and nitrogen rates on water use efficiency and nitrogen uptake in maize. **Agricultural water management**, v. 179, p. 271-276, 2017.

WANG, Z.; SKIDMORE, A. K.; WANG, T.; DARVISHZADEH, R.; HEARNE, J. Applicability of the PROSPECT model for estimating protein and cellulose+ lignin in fresh leaves. **Remote sensing of environment**, v. 168, p. 205-218, 2015.

WANG, Z.; WANG, T.; DARVISHZADEH, R.; SKIDMORE, A. K.; JONES, S.; SUAREZ, L.; HEARNE, J. Vegetation indices for mapping canopy foliar nitrogen in a mixed temperate forest. **Remote Sensing**, v. 8, n. 6, p. 491, 2016.

WEI, S.; WANG, X.; SHI, D.; LI, Y.; ZHANG, J.; LIU, P.; DONG, S. The mechanisms of low nitrogen induced weakened photosynthesis in summer maize (*Zea mays* L.) under field conditions. **Plant Physiology and Biochemistry**, v. 105, p. 118-128, 2016.

WOLD, S.; SJÖSTRÖM, M.; ERIKSSON, L. (2001). PLS-regression: A basic tool of chemometrics. **Chemometrics and Intelligent Laboratory Systems**, v. 58, n. 2, p. 109-130, out. 2001.

XIA, T.; MIAO, Y.; WU, D.; SHAO, H.; KHOSLA, R.; MI, G. Active Optical Sensing of Spring Maize for In-Season Diagnosis of Nitrogen Status Based on Nitrogen Nutrition Index. **Remote Sensing**, v. 8, n. 7, p. 605, 2016.

YANG, H.; YANG, J.; LV, Y.; HE, J. SPAD Values and Nitrogen Nutrition Index for the Evaluation of Rice Nitrogen Status. **Plant Prod. Sci**., v.17, p.81-92, 2014.

YANG, J.; DU, L.; SUN, J.; ZHANG, Z.; CHEN, B.; SHI, S.; SONG, S. Estimating the leaf nitrogen content of paddy rice by using the combined reflectance and laser-induced fluorescence spectra. **Optics express**, v. 24, n. 17, p. 19354-19365, 2016.

YU, K.; LI, F.; GNYP, M. L.; MIAO, Y.; BARETH, G.; CHEN, X. Remotely detecting canopy nitrogen concentration and uptake of paddy rice in the Northeast China Plain. **ISPRS journal of photogrammetry and remote sensing**, v. 78, p. 102-115, 2013.

YUAN, M.; COUTURE, J. J.; TOWNSEND, P. A.; RUARK, M. D.; BLAND, W. L. Spectroscopic Determination of Leaf Nitrogen Concentration and Mass Per Area in Sweet Corn and Snap Bean. **Agronomy Journal**, v. 108, n. 6, p. 2519-2526, 2016.

ZHAI, Y.; CUI, L.; ZHOU, X.; GAO, Y.; FEI, T.; GAO, W. Estimation of nitrogen, phosphorus, and potassium contents in the leaves of different plants using laboratory-based visible and near-infrared reflectance spectroscopy: comparison of partial least-square regression and support vector machine regression methods. **International journal of remote sensing**, v. 34, n. 7, p. 2502-2518, 2013.

ZHOU, L.; FENG, H.; YAN, Z.; LIU, K.; ZHOU, S. Hyperspectral diagnosis of leaf N concentration of maize and variety difference. **Transactions of the Chinese Society of Agricultural Engineering**, v. 26, n. 8, p. 195-199, 2010.

ZHOU, X.; HUANG, W.; KONG, W.; YE, H.; LUO, J.; CHEN, P. Remote estimation of canopy nitrogen content in winter wheat using airborne hyperspectral reflectance measurements. **Advances in Space Research**, v. 58, n. 9, p. 1627-1637, 2016.

ZHU, Y.; LI, Y.; FENG, W.; TIAN, Y.; YAO, X.; CAO, W. Monitoring leaf nitrogen in wheat using canopy reflectance spectra. **Canadian Journal of Plant Science**, v. 86, n. 4, p. 1037-1046, 2006.

ZOTARELLI, L.; DUKES, M. D.; SCHOLBERG, J. M. S.; FEMMINELLA, K.; MUNOZ-CARPENA, R. Irrigation scheduling for green bell peppers using capacitance soil moisture sensors. **Journal of Irrigation and Drainage Engineering**, v. 137, n. 2, p. 73-81, 2011.

# APÊNDICE A – TABELAS DAS ANÁLISES DE VARIÂNCIA

## 1. TABELAS DAS ANÁLISES DE VARIÂNCIA PARA AS VARÁVIES AVALIADAS NO CAPÍTULO I PARA O CICLO I

Variável analisada: ALURTA DE PLANTAS (CILO I)

Opção de transformação: Variável sem transformação ( Y )

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | Fc | Pr>Fc |
|---|---|---|---|---|---|
| BLOCO | 3 | 0.268308 | 0.089436 | 4.658 | 0.0314 |
| LAM | 3 | 2.112244 | 0.704081 | 36.668 | 0.0000 |
| erro 1 | 9 | 0.172812 | 0.019201 | | |
| ADUB | 3 | 1.288490 | 0.429497 | 31.269 | 0.0000 |
| LAM*ADUB | 9 | 0.271296 | 0.030144 | 2.195 | 0.0459 |
| erro 2 | 36 | 0.494479 | 0.013736 | | |
| Total corrigido | 63 | 4.607628 | | | |

CV 1 (%) = 8.31
CV 2 (%) = 7.03
Média geral: 1.6673438 Número de observações: 64

Variável analisada: ÍNDICE DE ÁREA FOLIAR (CILO I)

Opção de transformação: Variável sem transformação ( Y )

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | F |
|---|---|---|---|---|
| Blocos | 3 | 1.79538 | 0.59846 | 2.9753 ns |
| LAM(Ta) | 3 | 6.64462 | 2.21487 | 11.0116 ** |
| Resíduo-a | 9 | 1.81026 | 0.20114 | |
| Parcelas | 15 | 10.25025 | | |
| DOS(Tb) | 3 | 4.77945 | 1.59315 | 12.2153 ** |
| Int. TaxTb | 9 | 0.31221 | 0.03469 | 0.2660 * |
| Resíduo-b | 36 | 4.69519 | 0.13042 | |
| Total | 63 | 20.03710 | | |

** significativo ao nível de 1% de probabilidade (p < .01)
 * significativo ao nível de 5% de probabilidade (.01 =< p < .05)
ns não significativo (p >= .05)

CV%-a = 19.61
CV%-b = 15.79
Média geral = 2.28684
Número de observações: 64

Variável analisada: PRODUTIVIDADE DE ESPIGAS (CICLO I)

Opção de transformação: Variável sem transformação ( Y )

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | Fc | Pr>Fc |
|---|---|---|---|---|---|
| BLOC | 3 | 10117362.490237 | 3372454.163412 | 3.118 | 0.0809 |
| LAM | 3 | 199496612.535296 | 66498870.845099 | 61.475 | 0.0000 |
| erro 1 | 9 | 9735441.697517 | 1081715.744169 | | |
| DOS | 3 | 464367501.460711 | 154789167.153570 | 204.647 | 0.0000 |
| LAM*DOS | 9 | 23819441.643854 | 2646604.627095 | 3.499 | 0.0034 |
| erro 2 | 36 | 27229329.165846 | 756370.254607 | | |
| Total corrigido | 63 | 734765688.993461 | | | |

CV 1 (%) = 8.85
CV 2 (%) = 7.40
Média geral: 11750.8333342 Número de observações: 64

Variável analisada: EFICIÊNCIA DE USO DA ÁGUA - EUA (CICLO I)

Opção de transformação: Variável sem transformação ( Y )

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | Fc | Pr>Fc |
|---|---|---|---|---|---|
| BLOC | 3 | 0.571385 | 0.190462 | 2.520 | 0.1237 |
| LAM | 3 | 0.952708 | 0.317569 | 4.201 | 0.0408 |
| erro 1 | 9 | 0.680262 | 0.075585 | | |
| DOS | 3 | 23.141423 | 7.713808 | 201.051 | 0.0000 |
| LAM*DOS | 9 | 0.653969 | 0.072663 | 1.894 | 0.0847 |
| erro 2 | 36 | 1.381225 | 0.038367 | | |
| Total corrigido | 63 | 27.380971 | | | |

CV 1 (%) = 10.47
CV 2 (%) = 7.46
Média geral: 2.6262395 Número de observações: 64

Variável analisada: EFICIÊNCIA DE USO DE NITROGÊNIO – EUN (CICLO I)

Opção de transformação: Variável sem transformação ( Y )

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | Fc | Pr>Fc |
|---|---|---|---|---|---|

| | | | | | |
|---|---|---|---|---|---|
| BLOC | 3 | 626.615223 | 208.871741 | 2.152 | 0.1637 |
| LAM | 3 | 2241.762851 | 747.254284 | 7.699 | 0.0074 |
| erro 1 | 9 | 873.533794 | 97.059310 | | |
| DOS | 3 | 30680.375309 | 10226.791770 | 123.424 | 0.0000 |
| LAM*DOS | 9 | 1722.620020 | 191.402224 | 2.310 | 0.0363 |
| erro 2 | 36 | 2982.920435 | 82.858901 | | |
| Total corrigido | 63 | 39127.827633 | | | |

CV 1 (%) = 26.70
CV 2 (%) = 24.67
Média geral: 36.8964120 Número de observações: 64

## 2. TABELAS DAS ANÁLISES DE VARIÂNCIA PARA AS VARÁVIES AVALIADAS NO CAPÍTULO I PARA O CICLO II

Variável analisada: ALURTA DE PLANTAS (CILO II)

Opção de transformação: Variável sem transformação ( Y )

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | Fc | Pr>Fc |
|---|---|---|---|---|---|
| BLOC | 3 | 0.008874 | 0.002958 | 2.387 | 0.1366 |
| LAM | 3 | 0.185998 | 0.061999 | 50.034 | 0.0000 |
| erro 1 | 9 | 0.011152 | 0.001239 | | |
| DOSE | 3 | 0.423413 | 0.141138 | 87.457 | 0.0000 |
| LAM*DOSE | 9 | 0.043738 | 0.004860 | 3.011 | 0.0088 |
| erro 2 | 36 | 0.058097 | 0.001614 | | |
| Total corrigido | 63 | 0.731273 | | | |

CV 1 (%) = 1.93
CV 2 (%) = 2.21
Média geral: 1.8210261 Número de observações: 64

Variável analisada: ÍNDICE DE ÁREA FOLIAR (CICLO II)

Opção de transformação: Variável sem transformação ( Y )

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | Fc | Pr>Fc |
|---|---|---|---|---|---|
| BLOC | 3 | 0.341744 | 0.113915 | 6.171 | 0.0145 |
| LAM | 3 | 2.577770 | 0.859257 | 46.548 | 0.0000 |
| erro 1 | 9 | 0.166137 | 0.018460 | | |
| DOSE | 3 | 13.557986 | 4.519329 | 284.403 | 0.0000 |
| LAM*DOSE | 9 | 0.706581 | 0.078509 | 4.941 | 0.0002 |
| erro 2 | 36 | 0.572061 | 0.015891 | | |
| Total corrigido | 63 | 17.922278 | | | |

CV 1 (%) = 4.86
CV 2 (%) = 4.51
Média geral: 2.7928239 Número de observações: 64

---

Variável analisada: PRODUTIVIDADE DE ESPIGAS (CICLO II)

Opção de transformação: Variável sem transformação ( Y )

---

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | Fc | Pr>Fc |
|---|---|---|---|---|---|
| BLOC | 3 | 17028090.309910 | 5676030.103303 | 2.496 | 0.1258 |
| LAM | 3 | 21587986.143806 | 7195995.381269 | 3.165 | 0.0784 |
| erro 1 | 9 | 20463229.155979 | 2273692.128442 | | |
| DOSE | 3 | 226101076.296465 | 75367025.432155 | 57.453 | 0.0000 |
| LAM*DOSE | 9 | 34271354.210896 | 3807928.245655 | 2.903 | 0.0109 |
| erro 2 | 36 | 47224652.754389 | 1311795.909844 | | |
| Total corrigido | 63 | 366676388.871444 | | | |

CV 1 (%) = 10.31
CV 2 (%) = 7.83
Média geral: 14622.9166662 Número de observações: 64

---

Variável analisada: EFICIÊNCIA DE USO DA ÁGUA - EUA (CICLO II)

Opção de transformação: Variável sem transformação ( Y )

---

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | Fc | Pr>Fc |
|---|---|---|---|---|---|
| BLOC | 3 | 1.048554 | 0.349518 | 2.355 | 0.1399 |
| LAM | 3 | 4.868135 | 1.622712 | 10.936 | 0.0023 |
| erro 1 | 9 | 1.335485 | 0.148387 | | |
| DOSE | 3 | 11.934824 | 3.978275 | 48.013 | 0.0000 |
| LAM*DOSE | 9 | 1.146249 | 0.127361 | 1.537 | 0.1725 |
| erro 2 | 36 | 2.982882 | 0.082858 | | |
| Total corrigido | 63 | 23.316129 | | | |

CV 1 (%) = 11.10
CV 2 (%) = 8.29
Média geral: 3.4703430 Número de observações: 64

---

Variável analisada: EFICIÊNCIA DE USO DE NITROGÊNIO - EUN (CICLO II)

Opção de transformação: Variável sem transformação ( Y )

TABELA DE ANÁLISE DE VARIÂNCIA

| FV | GL | SQ | QM | Fc | Pr>Fc |
|---|---|---|---|---|---|
| BLOC | 3 | 1340.585672 | 446.861891 | 5.051 | 0.0254 |
| LAM | 3 | 6965.058382 | 2321.686127 | 26.240 | 0.0001 |
| erro 1 | 9 | 796.299921 | 88.477769 | | |
| DOSE | 3 | 25248.682198 | 8416.227399 | 58.901 | 0.0000 |
| LAM*DOSE | 9 | 4117.370759 | 457.485640 | 3.202 | 0.0060 |
| erro 2 | 36 | 5143.938823 | 142.887190 | | |
| Total corrigido | 63 | 43611.935755 | | | |

CV 1 (%) = 29.61
CV 2 (%) = 37.63
Média geral: 31.7693864 Número de observações: 64

# APÊNDICE B - ESTATÍSTICAS DAS SUPERFÍCIES DE RESPOSTA

## 1. VARIÁVEL: ALTURA DE PLANTAS CICLO I

Numeric Summary Feb 18, 2018 Page 1

Rank 1 Eqn 1 z=a+bx+cy

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err | F-value |
|---|---|---|---|
| 0.8618575668 | 0.8273219585 | 0.097781598 | 40.552884825 |

| Parm | Value | Std Error | t-value | 95.00% Confidence Limits | | P>\|t\| |
|---|---|---|---|---|---|---|
| a | 0.476564309 | 0.148883649 | 3.200917711 | 0.15492074 | 0.798207877 | 0.00696 |
| b | 0.002257984 | 0.000318758 | 7.083695216 | 0.001569349 | 0.002946619 | 0.00001 |
| c | 0.002026562 | 0.00036441 | 5.561207759 | 0.001239301 | 0.002813824 | 0.00009 |

| X at Fn Zmin | Y at Fn Zmin | Fn Zmin |
|---|---|---|
| 359.6 | 0 | 1.2885354167 |
| X at Fn Zmax | Y at Fn Zmax | Fn Zmax |
| 555.7 | 180 | 2.0961073627 |

Procedure
GaussElim

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err |
|---|---|---|
| 0.8618575668 | 0.8273219585 | 0.097781598 |

| Source | Sum of Squares | DF | Mean Square | F Statistic | P>F |
|---|---|---|---|---|---|
| Regr | 0.7754718 | 2 | 0.3877359 | 40.5529 | 0.00000 |
| Error | 0.12429613 | 13 | 0.0095612409 | | |
| Total | 0.89976793 | 15 | | | |

Description: alt ciclo 1.pdf, X , Y , Z

X Variable:

| | | | | | |
|---|---|---|---|---|---|
| Xmin: | 359.6 | Xmax: | 555.7 | Xrange: | 196.1 |
| Xmean: | 449.1 | Xstd: | 79.20461266 | | |

Y Variable:

| | | | | | |
|---|---|---|---|---|---|
| Ymin: | 0 | Ymax: | 180 | Yrange: | 180 |
| Ymean: | 90 | Ystd: | 69.282032303 | | |

Z Variable:

| | | | | | |
|---|---|---|---|---|---|
| Zmin: | 1.33525 | Zmax: | 2.09675 | Zrange: | 0.7615 |
| Zmean: | 1.673015625 | Zstd: | 0.244917392 | | |

| Date | Time | File Source |
|---|---|---|
| Feb 18, 2018 | 3:51:56 PM | c:\users\david\desktop\superficie de respo |

## 2. VARIÁVEL: ALTURA DE PLANTAS CICLO II

Numeric Summary Feb 18, 2018 Page 1

Rank 1 Eqn 1 z=a+bx+cy

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err | F-value |
|---|---|---|---|
| 0.8417382486 | 0.8021728108 | 0.0436314824 | 34.571199734 |

| Parm | Value | Std Error | t-value | 95.00% Confidence Limits | | P>\|t\| |
|---|---|---|---|---|---|---|
| a | 1.32847836 | 0.091260962 | 14.55691815 | 1.131321037 | 1.525635682 | 0.00000 |
| b | 0.000901555 | 0.000210195 | 4.289131668 | 0.000447456 | 0.001355655 | 0.00088 |
| c | 0.001158333 | 0.000162605 | 7.123605057 | 0.000807047 | 0.00150962 | 0.00001 |

| X at Fn Zmin | Y at Fn Zmin | Fn Zmin |
|---|---|---|
| 369.3 | 0 | 1.6614227456 |
| X at Fn Zmax | Y at Fn Zmax | Fn Zmax |
| 506 | 180 | 1.9931653602 |

Procedure
GaussElim

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err |
|---|---|---|
| 0.8417382486 | 0.8021728108 | 0.0436314824 |

| Source | Sum of Squares | DF | Mean Square | F Statistic | P>F |
|---|---|---|---|---|---|
| Regr | 0.13162682 | 2 | 0.065813409 | 34.5712 | 0.00001 |
| Error | 0.024748181 | 13 | 0.0019037063 | | |
| Total | 0.156375 | 15 | | | |

Description: altura ciclo 2.txt, X , Y , Z

X Variable:

| | | | | | |
|---|---|---|---|---|---|
| Xmin: | 369.3 | Xmax: | 506 | Xrange: | 136.7 |
| Xmean: | 425.4 | Xstd: | 53.595870488 | | |

Y Variable:

| | | | | | |
|---|---|---|---|---|---|
| Ymin: | 0 | Ymax: | 180 | Yrange: | 180 |
| Ymean: | 90 | Ystd: | 69.282032303 | | |

Z Variable:

| | | | | | |
|---|---|---|---|---|---|
| Zmin: | 1.69 | Zmax: | 1.98 | Zrange: | 0.29 |
| Zmean: | 1.81625 | Zstd: | 0.1021028893 | | |

| Date | Time | File Source |
|---|---|---|
| Feb 18, 2018 | 4:11:04 PM | c:\users\david\desktop\superficie de respo |

## 3. VARIÁVEL: ÍNDICE DE ÁREA FOLIAR CICLO I

Numeric Summary Feb 18, 2018 Page 1

Rank 394 Eqn 1 z=a+bx+cy

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err | F-value |
|---|---|---|---|
| 0.8731176051 | 0.8413970064 | 0.1623758531 | 44.728541243 |

| Parm | Value | Std Error | t-value | 95.00% Confidence Limits | | P>\|t\| |
|---|---|---|---|---|---|---|
| a | 0.237536596 | 0.247235779 | 0.960769503 | -0.29658383 | 0.771657023 | 0.35420 |
| b | 0.003874334 | 0.000529329 | 7.319336556 | 0.002730789 | 0.005017879 | 0.00001 |
| c | 0.003625 | 0.000605139 | 5.990358492 | 0.002317677 | 0.004932323 | 0.00005 |

| X at Fn Zmin | Y at Fn Zmin | Fn Zmin |
|---|---|---|
| 359.6 | 0 | 1.6307471061 |
| X at Fn Zmax | Y at Fn Zmax | Fn Zmax |
| 555.7 | 180 | 3.0430040055 |

Procedure
GaussElim

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err |
|---|---|---|
| 0.8731176051 | 0.8413970064 | 0.1623758531 |

| Source | Sum of Squares | DF | Mean Square | F Statistic | P>F |
|---|---|---|---|---|---|
| Regr | 2.3586181 | 2 | 1.179309 | 44.7285 | 0.00000 |
| Error | 0.34275693 | 13 | 0.026365918 | | |
| Total | 2.701375 | 15 | | | |

Description: IAF CICLO I.txt, X , Y , Z

X Variable:

| | | | | | |
|---|---|---|---|---|---|
| Xmin: | 359.6 | Xmax: | 555.7 | Xrange: | 196.1 |
| Xmean: | 449.1 | Xstd: | 79.20461266 | | |

Y Variable:

| | | | | | |
|---|---|---|---|---|---|
| Ymin: | 0 | Ymax: | 180 | Yrange: | 180 |
| Ymean: | 90 | Ystd: | 69.282032303 | | |

Z Variable:

| | | | | | |
|---|---|---|---|---|---|
| Zmin: | 1.56 | Zmax: | 3.15 | Zrange: | 1.59 |
| Zmean: | 2.30375 | Zstd: | 0.4243720852 | | |

| Date | Time | File Source |
|---|---|---|
| Feb 18, 2018 | 4:33:12 PM | C:\Users\David\Desktop\superficie de respo |

## 4. VARIÁVEL: ÍNDICE DE ÁREA FOLIAR CICLO I

Numeric Summary Feb 18, 2018 Page 1

Rank 285 Eqn 1 z=a+bx+cy

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err | F-value |
|---|---|---|---|
| 0.9414306177 | 0.9267882722 | 0.1375780127 | 104.47948704 |

| Parm | Value | Std Error | t-value | 95.00% Confidence Limits | | P>\|t\| |
|---|---|---|---|---|---|---|
| a | 0.565359178 | 0.28776244 | 1.964673284 | -0.05631378 | 1.187032134 | 0.07119 |
| b | 0.00378618 | 0.000662784 | 5.712538544 | 0.002354322 | 0.005218038 | 0.00007 |
| c | 0.006808333 | 0.000512723 | 13.27877545 | 0.005700663 | 0.007916004 | 0.00000 |

| X at Fn Zmin | Y at Fn Zmin | Fn Zmin |
|---|---|---|
| 369.3 | 0 | 1.9635953217 |
| X at Fn Zmax | Y at Fn Zmax | Fn Zmax |
| 506 | 180 | 3.7066660796 |

Procedure
GaussElim

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err |
|---|---|---|
| 0.9414306177 | 0.9267882722 | 0.1375780127 |

| Source | Sum of Squares | DF | Mean Square | F Statistic | P>F |
|---|---|---|---|---|---|
| Regr | 3.9551148 | 2 | 1.9775574 | 104.479 | 0.00000 |
| Error | 0.24606022 | 13 | 0.01892771 | | |
| Total | 4.201175 | 15 | | | |

Description: IAF CICLO II.txt, X , Y , Z

X Variable:

| | | | | | |
|---|---|---|---|---|---|
| Xmin: | 369.3 | Xmax: | 506 | Xrange: | 136.7 |
| Xmean: | 425.4 | Xstd: | 53.595870488 | | |

Y Variable:

| | | | | | |
|---|---|---|---|---|---|
| Ymin: | 0 | Ymax: | 180 | Yrange: | 180 |
| Ymean: | 90 | Ystd: | 69.282032303 | | |

Z Variable:

| | | | | | |
|---|---|---|---|---|---|
| Zmin: | 1.95 | Zmax: | 3.65 | Zrange: | 1.7 |
| Zmean: | 2.78875 | Zstd: | 0.5292242751 | | |

| Date | Time | File Source |
|---|---|---|
| Feb 18, 2018 | 4:42:11 PM | C:\Users\David\Desktop\superficie de respo |

## 5. VARIÁVEL: PRODUTIVIDADE DE ESPIGAS CICLO I

Numeric Summary Feb 18, 2018 Page 1

Rank 292 Eqn 17 $z=a+bx+cx^2+dy+ey^2$

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err | F-value |
|---|---|---|---|
| 0.9484336213 | 0.9226504319 | 897.74124428 | 50.579321677 |

| Parm | Value | Std Error | t-value | 95.00% Confidence Limits | | P>\|t\| |
|---|---|---|---|---|---|---|
| a | -29742.5339 | 12035.13959 | -2.47130776 | -56231.6975 | -3253.37024 | 0.03105 |
| b | 146.6540938 | 53.88432201 | 2.721646823 | 28.05550061 | 265.252687 | 0.01987 |
| c | -0.13626344 | 0.058816072 | -2.31677227 | -0.26571675 | -0.00681014 | 0.04081 |
| d | 58.46563417 | 11.70989428 | 4.992840478 | 32.69233061 | 84.23893772 | 0.00041 |
| e | -0.10685771 | 0.062343142 | -1.71402507 | -0.24407404 | 0.030358622 | 0.11453 |

| X at Fn Zmin | Y at Fn Zmin | Fn Zmin |
|---|---|---|
| 359.6 | 0 | 5373.757941 |
| X at Fn Zmax | Y at Fn Zmax | Fn Zmax |
| 538.12706216 | 180 | 16778.35883 |

Procedure
GaussElim

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err |
|---|---|---|
| 0.9484336213 | 0.9226504319 | 897.74124428 |

| Source | Sum of Squares | DF | Mean Square | F Statistic | P>F |
|---|---|---|---|---|---|
| Regr | 1.6305546e+08 | 4 | 40763865 | 50.5793 | 0.00000 |
| Error | 8865332.8 | 11 | 805939.34 | | |
| Total | 1.7192079e+08 | 15 | | | |

Description: produtividade ciclo 1.txt, X , Y , Z

X Variable:

| | | | | | |
|---|---|---|---|---|---|
| Xmin: | 359.6 | Xmax: | 555.7 | Xrange: | 196.1 |
| Xmean: | 449.1 | Xstd: | 79.20461266 | | |

Y Variable:

| | | | | | |
|---|---|---|---|---|---|
| Ymin: | 0 | Ymax: | 180 | Yrange: | 180 |
| Ymean: | 90 | Ystd: | 69.282032303 | | |

Z Variable:

| | | | | | |
|---|---|---|---|---|---|
| Zmin: | 6212.5 | Zmax: | 17054.16 | Zrange: | 10841.66 |
| Zmean: | 11750.831 | Zstd: | 3385.4669163 | | |

| Date | Time | File Source |
|---|---|---|
| Feb 18, 2018 | 4:58:36 PM | C:\Users\David\Desktop\superficie de respo |

## 6. VARIÁVEL: PRODUTIVIDADE DE ESPIGAS CICLO II

Numeric Summary Feb 18, 2018 Page 1

Rank 367 Eqn 17 $z=a+bx+cx^2+dy+ey^2$

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err | F-value |
|---|---|---|---|
| 0.8712675668 | 0.8069013503 | 908.2634231 | 18.612137983 |

| Parm | Value | Std Error | t-value | 95.00% Confidence Limits | | P>\|t\| |
|---|---|---|---|---|---|---|
| a | 8598.773247 | 22329.86699 | 0.385079466 | -40548.9327 | 57746.47915 | 0.70752 |
| b | 4.730589484 | 102.7772318 | 0.046027602 | -221.480573 | 230.9417516 | 0.96411 |
| c | 0.007138357 | 0.116706204 | 0.061165193 | -0.24973027 | 0.26400698 | 0.95232 |
| d | 37.82643333 | 11.84714274 | 3.192873941 | 11.75104796 | 63.90181871 | 0.00856 |
| e | -0.05584514 | 0.063073849 | -0.88539292 | -0.19466974 | 0.082979466 | 0.39489 |

| X at Fn Zmin | Y at Fn Zmin | Fn Zmin |
|---|---|---|
| 506 | 0 | 12820.128012 |
| X at Fn Zmax | Y at Fn Zmax | Fn Zmax |
| 506 | 180 | 17819.503512 |

Procedure
GaussElim

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err |
|---|---|---|
| 0.8712675668 | 0.8069013503 | 908.2634231 |

| Source | Sum of Squares | DF | Mean Square | F Statistic | P>F |
|---|---|---|---|---|---|
| Regr | 61415771 | 4 | 15353943 | 18.6121 | 0.00007 |
| Error | 9074366.9 | 11 | 824942.45 | | |
| Total | 70490137 | 15 | | | |

Description: produtividade ciclo 2.txt, X , Y , Z

X Variable:

| | | | | | |
|---|---|---|---|---|---|
| Xmin: | 369.3 | Xmax: | 506 | Xrange: | 136.7 |
| Xmean: | 425.4 | Xstd: | 53.595870488 | | |

Y Variable:

| | | | | | |
|---|---|---|---|---|---|
| Ymin: | 0 | Ymax: | 180 | Yrange: | 180 |
| Ymean: | 90 | Ystd: | 69.282032303 | | |

Z Variable:

| | | | | | |
|---|---|---|---|---|---|
| Zmin: | 11179.16 | Zmax: | 18179.16 | Zrange: | 7000 |
| Zmean: | 14622.91375 | Zstd: | 2167.7966912 | | |

| Date | Time | File Source |
|---|---|---|
| Feb 18, 2018 | 5:08:54 PM | C:\Users\David\Desktop\superficie de respo |

## 7. VARIÁVEL: EFICIÊNCIA DE USO DE NITROGÊNIO CICLO I

Numeric Summary Feb 18, 2018 Page 1

Rank 2 Eqn 2 $z=a+bx+cy+dy^2$

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err | F-value |
|---|---|---|---|
| 0.9215916612 | 0.893079538 | 7.522366307 | 47.014982097 |

| Parm | Value | Std Error | t-value | 95.00% Confidence Limits | | P>\|t\| |
|---|---|---|---|---|---|---|
| a | -31.3139777 | 11.60702336 | -2.6978474 | -56.6035092 | -6.02444632 | 0.01939 |
| b | 0.073173241 | 0.02452214 | 2.983966342 | 0.019744087 | 0.126602396 | 0.01140 |
| c | 1.027072917 | 0.098119714 | 10.46754902 | 0.813288425 | 1.240857409 | 0.00000 |
| d | -0.00453108 | 0.000522387 | -8.67379988 | -0.00566926 | -0.00339289 | 0.00000 |

| X at Fn Zmin | Y at Fn Zmin | Fn Zmin |
|---|---|---|
| 555.7 | 0 | 9.3483925414 |
| X at Fn Zmax | Y at Fn Zmax | Fn Zmax |
| 555.7 | 113.3365263 | 67.550830859 |

Procedure
GaussElim

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err |
|---|---|---|
| 0.9215916612 | 0.893079538 | 7.522366307 |

| Source | Sum of Squares | DF | Mean Square | F Statistic | P>F |
|---|---|---|---|---|---|
| Regr | 7981.1686 | 3 | 2660.3895 | 47.015 | 0.00000 |
| Error | 679.03194 | 12 | 56.585995 | | |
| Total | 8660.2005 | 15 | | | |

Description: eficienacia N ciclo 1.txt, X , Y , Z

X Variable:

| | | | | | |
|---|---|---|---|---|---|
| Xmin: | 359.6 | Xmax: | 555.7 | Xrange: | 196.1 |
| Xmean: | 449.1 | Xstd: | 79.20461266 | | |

Y Variable:

| | | | | | |
|---|---|---|---|---|---|
| Ymin: | 0 | Ymax: | 180 | Yrange: | 180 |
| Ymean: | 90 | Ystd: | 69.282032303 | | |

Z Variable:

| | | | | | |
|---|---|---|---|---|---|
| Zmin: | 0 | Zmax: | 66.77 | Zrange: | 66.77 |
| Zmean: | 36.893125 | Zstd: | 24.028039931 | | |

| Date | Time | File Source |
|---|---|---|
| Feb 18, 2018 | 6:12:10 PM | C:\Users\David\Desktop\superficie de respo |

## 8. VARIÁVEL: EFICIÊNCIA DE USO DE NITROGÊNIO CICLO II

Numeric Summary Feb 18, 2018 Page 1

Rank 2 Eqn 2 $z=a+bx+cy+dy^2$

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err | F-value |
|---|---|---|---|
| 0.6866207525 | 0.5726646625 | 15.400146793 | 8.7640870656 |

| Parm | Value | Std Error | t-value | 95.00% Confidence Limits | | P>\|t\| |
|---|---|---|---|---|---|---|
| a | -69.3066531 | 32.4406947 | -2.13641088 | -139.988855 | 1.375548762 | 0.05394 |
| b | 0.172608787 | 0.074190432 | 2.326563976 | 0.010961721 | 0.334255853 | 0.03831 |
| c | 0.879664583 | 0.200875355 | 4.379156341 | 0.441994783 | 1.317334384 | 0.00090 |
| d | -0.00408941 | 0.001069455 | -3.82382719 | -0.00641955 | -0.00175927 | 0.00242 |

| X at Fn Zmin | Y at Fn Zmin | Fn Zmin |
|---|---|---|
| 506 | 0 | 18.033393254 |
| X at Fn Zmax | Y at Fn Zmax | Fn Zmax |
| 506 | 107.55398002 | 65.339106776 |

Procedure
GaussElim

| $r^2$ Coef Det | DF Adj $r^2$ | Fit Std Err |
|---|---|---|
| 0.6866207525 | 0.5726646625 | 15.400146793 |

| Source | Sum of Squares | DF | Mean Square | F Statistic | P>F |
|---|---|---|---|---|---|
| Regr | 6235.5915 | 3 | 2078.5305 | 8.76409 | 0.00237 |
| Error | 2845.9743 | 12 | 237.16452 | | |
| Total | 9081.5658 | 15 | | | |

Description: eficienacia N ciclo 2.txt, X , Y , Z

X Variable:

| | | | | | |
|---|---|---|---|---|---|
| Xmin: | 369.3 | Xmax: | 506 | Xrange: | 136.7 |
| Xmean: | 425.4 | Xstd: | 53.595870488 | | |

Y Variable:

| | | | | | |
|---|---|---|---|---|---|
| Ymin: | 0 | Ymax: | 180 | Yrange: | 180 |
| Ymean: | 90 | Ystd: | 69.282032303 | | |

Z Variable:

| | | | | | |
|---|---|---|---|---|---|
| Zmin: | 0 | Zmax: | 82.15 | Zrange: | 82.15 |
| Zmean: | 31.764375 | Zstd: | 24.60564406 | | |

| Date | Time | File Source |
|---|---|---|
| Feb 18, 2018 | 6:31:51 PM | C:\Users\David\Desktop\superficie de respo |

# APÊNDICE C - RESULTADOS DAS ANÁLISE FATORIAIS PARA OS MODELOS PLSR DO CAPÍTULO III

## 1. MODELO R3 2015 – LABORATÓRIO (VER TALEBA 11)

| FATORES | | | | | | |
|---|---|---|---|---|---|---|
| FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| 48,93801 | 1,276522 | 5,177997 | 1,132935 | -2,63039 | -5,48373 | 0,47361 |
| 10,12551 | 11,0436 | 8,402017 | -0,12092 | -3,47634 | 8,31883 | -2,84397 |
| 37,0455 | 15,31326 | -4,93111 | 5,946914 | -0,82772 | 1,731289 | 0,263601 |
| 7,020448 | -16,222 | -3,11191 | -0,31166 | 2,622567 | 4,596398 | 0,493444 |
| 39,81726 | 12,54981 | 5,932462 | -1,14204 | 2,849778 | 3,346149 | 3,594754 |
| 50,32096 | 1,729295 | 2,21413 | -0,79369 | -0,72475 | -8,94409 | -2,20351 |
| 45,81033 | 7,125355 | -10,7426 | -0,34388 | -0,77021 | -1,98449 | -1,12295 |
| 10,87696 | -2,51272 | -7,0805 | -0,23513 | 0,223221 | 0,89149 | 0,119843 |
| -27,5379 | -33,7183 | 6,458879 | -3,41174 | -0,41859 | 3,079634 | 3,696107 |
| 27,14668 | 18,58129 | 8,795215 | -2,67549 | -0,32091 | -1,44607 | -0,28855 |
| 9,159678 | -8,08582 | -8,10505 | -0,78102 | -1,31512 | -1,54212 | 1,822242 |
| -27,4759 | -0,46629 | 5,707192 | -0,54808 | 0,798277 | -0,56747 | -2,12592 |
| 14,47216 | -14,9593 | -15,6258 | -0,81889 | -0,65339 | -1,9448 | 3,259566 |
| -31,3295 | -6,88889 | 3,670095 | -1,38116 | 2,297132 | -1,80644 | -2,74584 |
| -24,5854 | -9,77314 | -8,438 | -1,35354 | 2,06603 | -2,32158 | 0,392237 |
| -57,2275 | 38,35944 | -7,69822 | -2,8234 | -1,46859 | -0,52086 | 0,476369 |
| -60,9698 | 4,253833 | 10,59339 | 3,732551 | 2,210472 | -2,51071 | 3,215291 |
| -40,8912 | -2,99935 | 8,470212 | -2,49772 | -5,27407 | 0,914542 | 0,048602 |
| 75,162 | -1,54001 | 1,368947 | 4,679102 | 3,477913 | -1,179 | -0,03377 |
| -85,5284 | 19,11486 | -5,50699 | -2,64873 | 1,208037 | 0,118417 | 1,205944 |
| 32,29493 | -3,66112 | -12,2541 | -4,13676 | -0,8991 | 0,866459 | 2,590029 |
| -8,65798 | -17,0374 | -16,0759 | 1,756053 | -0,74816 | -0,07956 | -4,45576 |
| -83,7154 | 0,417188 | 3,712652 | 4,964735 | -1,10005 | -2,12587 | 2,837883 |
| -60,5145 | -13,1504 | 6,412428 | 0,441911 | 2,637567 | 0,812748 | -1,87789 |
| 15,1786 | 3,307665 | 11,93154 | -0,35008 | 2,471411 | 0,464586 | 1,921899 |
| -14,1581 | -0,24337 | -0,44537 | 2,248784 | 0,283988 | 5,597886 | -0,79467 |
| -2,81297 | -1,53027 | 14,79628 | -1,59641 | -2,59167 | -0,76001 | -0,29428 |
| 10,87696 | -2,51272 | -7,0805 | -0,23513 | 0,223221 | 0,89149 | 0,119843 |

| | | | | | | |
|---|---|---|---|---|---|---|
| -42,945 | 8,622712 | -5,11013 | -3,33262 | 2,172627 | -4,5035 | -1,52732 |
| 45,27678 | 3,657696 | -1,79966 | -0,58345 | -0,64928 | 2,135076 | 0,938609 |
| 16,9502 | -1,14121 | -2,30957 | -3,07513 | -1,12074 | -1,25901 | -0,28201 |
| 40,18961 | -0,30306 | 7,299261 | 0,484988 | 0,5969 | -3,64761 | 0,563093 |
| 10,22143 | 11,44509 | -6,05223 | 0,791681 | 2,903627 | 6,103094 | -1,01039 |
| -32,2162 | -10,218 | -1,31877 | 0,549962 | 0,895893 | 0,055243 | -2,81985 |
| 65,11259 | -10,8236 | 5,97784 | -0,34821 | -1,84241 | 2,468746 | -3,50888 |
| 53,96542 | 2,635213 | -3,91539 | 4,09483 | -1,35119 | 0,896722 | 2,170384 |
| 27,97923 | -7,47276 | 1,033042 | 0,410632 | -0,00391 | -0,44367 | 0,483525 |
| 3,398083 | -0,57766 | 16,77982 | 1,248008 | -0,16059 | 2,763866 | -0,015 |
| 27,14668 | 18,58129 | 8,795215 | -2,67549 | -0,32091 | -1,44607 | -0,28855 |
| -8,12261 | 10,79835 | -2,49253 | 0,108685 | 4,717855 | 1,007097 | -1,68059 |
| 45,27678 | 3,657696 | -1,79966 | -0,58345 | -0,64928 | 2,135076 | 0,938609 |
| -27,4759 | -0,46629 | 5,707192 | -0,54808 | 0,798277 | -0,56747 | -2,12592 |
| 12,43042 | 2,663801 | -0,33272 | 1,946753 | 2,417844 | -4,23356 | -0,07848 |
| -78,8964 | 1,148765 | -0,87828 | 6,456287 | -4,29554 | -1,7788 | -0,18697 |
| 3,847217 | -1,21239 | -0,58426 | -0,74315 | -1,97684 | -1,13944 | 0,384913 |
| -27,5069 | -17,0923 | 6,083033 | -1,97991 | 0,189844 | 1,256085 | 0,785095 |
| -38,4774 | 10,77728 | -17,7651 | 0,451965 | -1,7798 | 3,419974 | 0,000661 |
| -4,9954 | -22,4516 | -3,86451 | 0,628155 | -0,69289 | -1,63499 | -0,48508 |

| VARIÂNCIA EXPLICADA x | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 84,13428 | 91,60843 | 95,25347 | 95,61068 | 96,06428 | 96,65031 | 96,93713 |
| VALIDAÇÃO | 0 | 83,72734 | 90,72195 | 94,45041 | 94,64598 | 95,14597 | 95,50422 | 95,84585 |

| VARIÂNCIA EXPLICADA y | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 21,70452 | 51,24014 | 56,56339 | 70,32749 | 76,59528 | 80,40823 | 84,20586 |
| VALIDAÇÃO | 0 | 21,448 | 46,79162 | 48,29992 | 28,3557 | 21,96641 | 7,372421 | 1,686893 |

| ERRO DA VALIDAÇÃO CRUZADA | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0,340858 | 0,301607 | 0,238015 | 0,224647 | 0,185674 | 0,164902 | 0,150873 | 0,135463 |
| VALIDAÇÃO | 0,34848 | 0,315908 | 0,260047 | 0,254778 | 0,299747 | 0,31345 | 0,342304 | 0,353064 |

## 2. MODELO V8 2016 – LABORATÓRIO (VER TALEBA 11)

| FATORES | | | | | | |
|---|---|---|---|---|---|---|
| FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| 13,66125 | 8,809105 | -14,3544 | 2,569376 | 2,048717 | -2,75456 | 0,48317 |
| 20,22184 | -14,1063 | -2,38002 | 14,66619 | -0,56463 | 1,691993 | 2,455295 |
| 40,76047 | -15,8756 | -4,14179 | 3,659729 | 2,587539 | -1,80596 | -0,63662 |
| -4,53092 | 9,034497 | -6,05891 | -4,25774 | -4,92015 | -2,37035 | 0,969809 |
| 16,69562 | -77,7096 | 3,891038 | 3,211896 | -0,39418 | -0,67266 | 4,453174 |
| 12,84738 | 9,625422 | 9,511615 | -6,57821 | 0,203572 | 0,390674 | 2,840095 |
| 15,40559 | 18,77161 | 9,390766 | 0,251901 | -2,22571 | -0,03557 | -0,09592 |
| -56,2822 | 49,37159 | 9,43802 | 33,58836 | -1,651 | 0,956052 | -1,5885 |
| 24,33614 | -0,85193 | 3,079728 | -5,33166 | -1,05387 | -2,68985 | -0,91651 |
| 16,22994 | 38,69196 | -4,74857 | 4,590232 | -2,08842 | -2,37843 | 1,207052 |
| 2,314475 | 73,12103 | -10,1219 | -15,2807 | 1,800457 | -0,81214 | -2,72852 |
| 5,061971 | -47,4428 | 10,59322 | -1,72089 | 2,052395 | 0,840689 | 0,868142 |
| 17,20976 | 48,47755 | 5,46684 | 5,134161 | 0,778686 | -0,7175 | 0,452048 |
| -9,41239 | -4,18998 | 5,571115 | -4,66346 | 2,229643 | -0,79102 | -1,69423 |
| -7,05331 | -15,2331 | -14,5561 | 7,594809 | 0,712697 | 1,907867 | 0,362818 |
| 8,195286 | -39,6036 | 8,777447 | 8,098949 | 0,915262 | -1,92808 | 4,439679 |
| -17,0141 | 19,75857 | -13,7004 | -4,98407 | -1,05861 | 0,882518 | 2,581739 |
| -7,45423 | 26,41226 | 1,749944 | 1,538318 | 3,364681 | -0,23803 | 3,405094 |
| -7,54316 | -7,78901 | -13,5314 | -3,73287 | 1,713157 | 1,38154 | -2,83903 |
| 9,103239 | 6,413417 | -0,79839 | 2,561778 | 2,733437 | 0,301598 | 1,851354 |
| -9,13338 | -59,902 | -11,6616 | -1,23398 | 1,45626 | 0,959429 | -0,96626 |
| -14,8648 | -36,879 | 2,372926 | -14,7679 | -2,05231 | 0,720499 | -1,54699 |
| 20,19039 | 29,78457 | 5,198867 | -3,78998 | -2,5313 | 1,80547 | 2,219222 |
| 2,107093 | 10,57417 | -6,79765 | -8,70773 | 0,875118 | -1,71916 | -1,39693 |
| 12,68732 | -1,58503 | 9,839437 | 6,8104 | 1,163462 | 3,440313 | -1,88542 |
| -12,3862 | 6,719514 | -7,62635 | 5,589463 | -1,4855 | -1,85466 | 2,66419 |
| 6,149849 | 35,58009 | 3,950045 | 1,508496 | -1,62109 | 3,358935 | -0,39347 |
| -12,2172 | 43,04145 | -5,66831 | -1,66332 | -0,53291 | -4,19843 | -1,73265 |
| -42,8934 | -45,1984 | 8,860068 | -9,70997 | 0,272469 | -5,26964 | -0,38366 |
| -37,6332 | -14,5319 | 6,035534 | -4,54661 | 2,426134 | 1,480275 | 3,126688 |
| 24,837 | -25,4992 | -14,806 | 4,887962 | 0,917522 | 2,434622 | -1,27902 |

| | | | | | | |
|---|---|---|---|---|---|---|
| -20,5243 | 16,59126 | -17,5289 | -0,73237 | 0,360986 | 2,336602 | 3,871038 |
| -4,95697 | 27,18645 | -8,43853 | -6,12314 | -1,33487 | -0,87191 | 3,017632 |
| -2,1531 | -18,1289 | -15,6163 | 0,082052 | -1,08342 | 1,615953 | -2,40056 |
| -23,4483 | -10,6189 | 16,44275 | -4,84026 | 0,256345 | -1,77775 | -1,40959 |
| -2,89593 | 84,8296 | 16,07136 | -11,3691 | 1,976407 | 1,540288 | -0,84094 |
| -25,2183 | -35,4372 | -14,3242 | 3,552494 | -0,37115 | -0,43187 | 1,880319 |
| 0,395587 | -45,183 | 18,91666 | -7,80287 | -1,04314 | 3,775779 | -0,85486 |
| 11,90446 | 12,59105 | -1,55205 | 9,019199 | 1,01153 | -0,81026 | -3,2593 |
| -10,7988 | 17,45425 | 13,09316 | 6,785128 | 3,433005 | 1,091566 | -0,65 |
| 19,70609 | -18,8082 | -1,72996 | 12,38145 | -0,55564 | -4,60461 | -2,49725 |
| -7,11947 | -26,4493 | -18,0605 | -4,45977 | 0,02503 | 3,295106 | -5,99122 |
| 13,96541 | 30,05679 | 5,47667 | 0,148221 | -2,05168 | 2,511714 | -0,43808 |
| 2,176858 | 15,40523 | 2,667909 | -7,91583 | -1,31118 | -0,05749 | 0,244753 |
| 4,517073 | -35,7163 | 6,863547 | -9,68763 | -0,90862 | 1,170027 | 2,332459 |
| 10,17226 | 22,93872 | 4,596889 | -1,85472 | 0,557601 | 0,079531 | 0,968883 |
| 3,682273 | -38,9188 | 14,5789 | 6,165616 | 0,422246 | -2,17522 | -5,88326 |
| 0,998862 | -25,5823 | 5,767764 | 1,358482 | -5,455 | 0,996085 | -2,38588 |

| VARIÂNCIA EXPLICADA x | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 30,22095 | 85,98009 | 92,5462 | 96,31075 | 96,59376 | 96,94659 | 97,30956 |
| VALIDAÇÃO | 0 | 12,5735 | 83,61189 | 91,00417 | 95,24396 | 95,53745 | 95,78943 | 96,07789 |

| VARIÂNCIA EXPLICADA y | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 53,9957 | 68,62018 | 74,03019 | 77,03713 | 87,04559 | 92,51576 | 95,44165 |
| VALIDAÇÃO | 0 | 38,99694 | 63,73743 | 67,43599 | 68,86659 | 55,41098 | 55,28704 | 52,75058 |

| ERRO DA VALIDAÇÃO CRUZADA | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0,410839 | 0,278657 | 0,230142 | 0,209366 | 0,196872 | 0,14787 | 0,112395 | 0,087715 |
| VALIDAÇÃO | 0,416755 | 0,325504 | 0,250963 | 0,237821 | 0,232538 | 0,278288 | 0,278675 | 0,28647 |

## 3. MODELO R1 2016 – LABORATÓRIO (VER TALEBA 11)

| FATORES | | | | | | |
|---|---|---|---|---|---|---|
| **FATOR 1** | **FATOR 2** | **FATOR 3** | **FATOR 4** | **FATOR 5** | **FATOR 6** | **FATOR 7** |
| **0,524764** | **0,537044** | **0,478446** | **0,441624** | **0,540059** | **0,369101** | **0,27536** |
| **-0,01635** | **-0,34687** | **-0,50449** | **-0,27509** | **-0,19267** | **0,354634** | **0,27559** |
| **-1,36912** | **-1,15321** | **0,600297** | **0,285771** | **0,436726** | **0,270652** | **0,297534** |
| **1,174097** | **1,450594** | **0,729834** | **0,510004** | **0,588835** | **0,186463** | **0,294739** |
| **0,79532** | **0,865721** | **0,442607** | **0,020764** | **0,1214** | **0,564534** | **0,26985** |
| **0,632986** | **0,353124** | **0,667544** | **0,703017** | **0,540049** | **0,221406** | **-0,0599** |
| **0,79532** | **1,080623** | **0,330234** | **0,300954** | **0,287568** | **0,200192** | **0,245463** |
| **-1,36912** | **-1,45947** | **-0,93339** | **-0,96392** | **-0,76512** | **-0,52326** | **-0,49561** |
| **0,660042** | **1,210935** | **0,197849** | **0,185587** | **0,381771** | **0,316221** | **0,048262** |
| **-0,55746** | **-1,31912** | **-0,57086** | **-0,40279** | **-0,02113** | **0,074281** | **0,307495** |
| **1,33643** | **1,267269** | **0,418394** | **0,306523** | **0,501808** | **0,549349** | **0,094853** |
| **1,201153** | **0,699371** | **0,903587** | **0,883364** | **0,608723** | **0,135615** | **0,025764** |
| **1,796374** | **1,092063** | **0,959766** | **0,755279** | **0,233335** | **0,149953** | **0,131442** |
| **-0,96329** | **-0,40431** | **-0,768** | **-0,94927** | **-0,60745** | **-0,55633** | **-0,33725** |
| **-0,55746** | **-0,53021** | **-0,67449** | **-0,18335** | **-0,11941** | **-0,05417** | **-0,41675** |
| **-2,18079** | **-1,36113** | **0,645262** | **0,323451** | **0,552818** | **0,307769** | **0,049756** |
| **0,254209** | **-0,33975** | **0,091726** | **-0,08385** | **0,084283** | **-0,09194** | **-0,27614** |
| **0,79532** | **0,671553** | **-0,1111** | **-0,22439** | **0,014936** | **0,28195** | **0,350426** |
| **-0,01635** | **-0,00941** | **0,098008** | **0,111084** | **-0,05183** | **-0,07753** | **-0,01604** |
| **-0,01635** | **-0,38565** | **0,235539** | **0,24398** | **0,170545** | **-0,24525** | **-0,1261** |
| **-0,12457** | **0,103089** | **0,283101** | **0,287097** | **0,359375** | **0,209473** | **-0,00896** |
| **-0,44923** | **-0,87991** | **-0,59412** | **-0,39333** | **-0,38828** | **-0,05948** | **-0,05338** |
| **0,497708** | **0,086703** | **0,308198** | **0,162172** | **0,045069** | **-0,11543** | **0,041086** |
| **-2,45134** | **-1,57471** | **-0,27614** | **-0,40454** | **-0,64461** | **-0,46786** | **0,043246** |
| **-0,61157** | **-0,72127** | **-0,65824** | **-1,00793** | **-0,80783** | **-0,52155** | **-0,32667** |
| **-0,55746** | **-0,14816** | **-0,53928** | **-0,68821** | **-0,5793** | **-0,77919** | **-0,66899** |
| **1,309375** | **1,572195** | **0,137318** | **0,103932** | **0,159504** | **-0,10533** | **0,17311** |
| **-0,01635** | **0,141941** | **-0,21123** | **-0,15637** | **-0,63958** | **-0,48458** | **-0,14071** |
| **-0,2869** | **-0,84273** | **-0,78336** | **-0,5658** | **-0,44901** | **-0,63914** | **-0,27845** |
| **-0,96329** | **-1,42582** | **-1,06788** | **-0,78637** | **-0,54564** | **-0,32944** | **-0,29179** |
| **1,092931** | **1,201292** | **-0,01699** | **-0,09888** | **-0,013** | **-0,2422** | **-0,09242** |

| | | | | | | |
|---|---|---|---|---|---|---|
| 1,065875 | 0,657163 | 0,599729 | 0,592497 | 0,103327 | 0,085172 | -0,25992 |
| 0,524764 | 0,317327 | 0,372974 | 0,389009 | 0,397039 | 0,309465 | -0,15979 |
| 1,065875 | -0,0229 | 0,179285 | 0,271977 | 0,215254 | -0,07569 | -0,03025 |
| 1,065875 | 0,716754 | 0,563696 | 0,745827 | 0,454073 | 0,263114 | 0,417809 |
| -0,01635 | 0,22184 | 0,444171 | 0,423257 | 0,637739 | 0,682764 | 0,729052 |
| -0,55746 | -0,57362 | -0,27688 | 0,026633 | 0,173311 | -0,05693 | -0,11629 |
| -0,55746 | -0,04551 | 0,232226 | 0,616369 | 0,610098 | 0,526792 | 0,450426 |
| -1,5044 | -1,4817 | -1,30928 | -1,2859 | -1,1345 | -0,73291 | -0,38023 |
| 0,741209 | 0,733856 | 0,2126 | 0,098848 | -0,14936 | -0,43001 | -0,21559 |
| 0,389486 | -0,3172 | -0,0364 | 0,050382 | -0,06982 | 0,305723 | 0,374291 |
| -1,2609 | 0,371974 | 0,226307 | 0,400568 | -0,01933 | -0,01897 | 0,016741 |
| -0,69274 | -0,09629 | 0,247834 | -0,09632 | -0,15891 | 0,117401 | -0,10448 |
| -0,96329 | 0,005268 | 0,01007 | 0,291907 | -0,15038 | 0,026213 | -0,09944 |
| 1,606986 | 0,935677 | 0,28283 | -0,12935 | -0,25081 | 0,039419 | 0,139846 |
| -0,55746 | -0,60668 | -0,31067 | -0,0469 | -0,442 | 0,113236 | -0,00725 |
| 0,524764 | 0,515151 | -0,27128 | -0,44255 | -0,22972 | -0,07642 | -0,21263 |
| -1,23385 | -0,7629 | -0,98536 | -0,3468 | 0,212029 | 0,022691 | 0,122838 |

| VARIÂNCIA EXPLICADA x | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 59,50403 | 78,24902 | 93,52635 | 94,86691 | 95,55936 | 96,03578 | 96,2972 |
| VALIDAÇÃO | 0 | 57,20368 | 70,87368 | 92,10819 | 93,89127 | 94,4582 | 94,85172 | 94,98895 |

| VARIÂNCIA EXPLICADA y | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 26,56531 | 69,70163 | 74,92495 | 80,93687 | 87,62244 | 92,40694 | 96,88325 |
| VALIDAÇÃO | 0 | 14,04209 | 64,98875 | 70,96541 | 73,07027 | 70,15039 | 65,6469 | 61,9277 |

| ERRO DA VALIDAÇÃO CRUZADA | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0,36574 | 0,313417 | 0,201318 | 0,183144 | 0,159687 | 0,128674 | 0,100781 | 0,064569 |
| VALIDAÇÃO | 0,371493 | 0,338728 | 0,223173 | 0,20656 | 0,198889 | 0,210656 | 0,22532 | 0,23889 |

## 4. MODELO R3 2016 – LABORATÓRIO (VER TALEBA 11)

| FATORES | | | | | | |
|---|---|---|---|---|---|---|
| FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| 18,08433 | 36,28519 | 6,71911 | -1,9956 | -1,48757 | -0,0443 | -2,41347 |
| 8,935802 | 30,7997 | 4,533359 | 3,980848 | -1,00724 | 1,231637 | -0,07445 |
| 8,175111 | -7,9898 | 17,50795 | 1,364528 | 0,915242 | 0,934067 | -2,16383 |
| 14,69742 | -2,27876 | 6,40289 | 8,756992 | -0,13323 | -1,11854 | 1,517391 |
| 23,3475 | 12,77268 | -56,6215 | 18,21236 | 1,509464 | -2,44185 | -0,75186 |
| -11,4878 | -13,4698 | -13,4522 | -3,96445 | -2,55127 | 0,053026 | 1,247983 |
| -7,77451 | -2,96649 | -12,1355 | 0,465009 | -1,61205 | -1,1513 | 0,267955 |
| -1,43503 | 19,52547 | -7,49067 | -2,44212 | 0,685594 | 3,823359 | -0,11679 |
| 8,174077 | -25,6867 | 6,589723 | 0,783738 | 0,91482 | 2,686023 | -1,57976 |
| 7,933669 | 20,65679 | 9,209234 | -2,72137 | 1,809536 | -1,48088 | 0,124857 |
| 2,66681 | 6,618046 | -3,06558 | -4,51532 | -0,37623 | -0,10873 | 1,178141 |
| 18,67344 | 8,154885 | -10,4086 | -2,4269 | 1,81462 | 3,445475 | -1,54634 |
| 16,25741 | 6,00053 | -16,3023 | -1,92943 | 1,073242 | 0,410735 | -0,64777 |
| 0,264596 | -32,586 | 9,687607 | -1,43112 | 0,040858 | -0,94761 | -1,32614 |
| 1,202802 | -43,31 | 15,64327 | 10,19621 | -3,69568 | 0,088704 | -0,22249 |
| -6,89115 | -94,4369 | -11,4252 | -4,162 | 0,176648 | 0,590164 | 1,514714 |
| 12,87123 | 20,56332 | -2,06143 | -1,25158 | 0,429503 | -0,25997 | 0,192764 |
| 14,29422 | 18,01692 | 1,016253 | -4,42366 | -0,83107 | -0,46801 | 3,257755 |
| 9,898171 | -33,0387 | -2,81339 | 2,205656 | 2,304545 | 0,03153 | -0,44645 |
| 20,47477 | 14,4223 | 5,466909 | 2,200306 | 0,199895 | -1,47065 | -2,19352 |
| 9,68962 | -29,2066 | -7,36047 | -4,34402 | 3,313615 | -0,30721 | 0,852177 |
| 6,682517 | -7,0328 | 1,231967 | -0,63521 | 1,213042 | -0,32525 | 0,410947 |
| -16,2551 | 30,81996 | -4,93572 | 0,134202 | -0,91499 | -1,74514 | -1,13811 |
| 11,65186 | 17,08587 | -3,61536 | -3,95619 | -0,29623 | -1,87046 | 0,54614 |
| -53,8695 | 29,22475 | 16,4185 | 4,39113 | 2,591721 | 0,846789 | 0,109423 |
| 17,37212 | 34,12223 | -10,2601 | -2,64808 | -0,8858 | 0,020149 | 2,159754 |
| -31,4886 | 0,778605 | -1,04125 | 1,697196 | -0,17912 | -3,60863 | -2,07092 |
| 6,646726 | 3,274098 | 10,62339 | 0,036792 | -1,36498 | -0,07688 | -1,45583 |
| 6,670566 | -33,1071 | 10,67493 | 8,692396 | -5,59835 | 3,646214 | -0,07699 |
| 15,03752 | 8,506317 | 13,36077 | 5,03627 | -0,87737 | 2,378487 | 1,528984 |
| 1,693139 | 63,31862 | 13,02976 | -0,45319 | 0,691381 | -3,00309 | -1,10515 |

| | | | | | | |
|---|---|---|---|---|---|---|
| 17,3665 | 36,05095 | 0,315895 | -3,2638 | 0,951134 | 2,55887 | 0,52365 |
| 9,496891 | -23,5574 | 14,91914 | -0,44806 | 0,103331 | -2,19982 | 0,742789 |
| 8,42395 | -18,9564 | 15,57544 | -0,45796 | 3,738225 | 1,429051 | 0,813018 |
| -9,38342 | -6,50859 | 1,008906 | -6,85814 | -0,58862 | -0,27285 | -3,62619 |
| -6,30793 | 22,33652 | -0,06156 | -0,66875 | -0,52595 | -1,5054 | 0,539981 |
| -38,8553 | -1,88887 | -11,8154 | -2,77816 | -2,76707 | 0,017253 | -0,25712 |
| -9,80656 | -11,5106 | -5,06713 | -2,75936 | 1,473497 | -3,60975 | 3,246919 |
| -74,9929 | 22,8959 | 5,734372 | 7,811711 | 4,462276 | 2,503762 | 1,509161 |
| -30,1946 | 3,227359 | -6,10186 | -1,29625 | -5,84695 | -2,57487 | 0,773928 |
| 2,143008 | -54,956 | 2,08628 | 0,068797 | 0,960827 | 0,922203 | -0,38352 |
| -47,4442 | -6,72512 | -17,4151 | -4,28924 | 0,36377 | 2,626055 | -1,33275 |
| 16,41235 | 40,21268 | 1,116275 | 0,409014 | 2,408576 | 3,036616 | 1,6767 |
| 3,370159 | -34,1999 | 22,21809 | 0,743277 | 0,317501 | -4,70733 | 0,304719 |
| 3,300142 | 15,51581 | -5,89734 | -7,12511 | -1,18577 | -0,80094 | -0,81383 |
| 9,081797 | -46,4846 | -11,8996 | -2,48668 | 5,207454 | -0,66882 | -0,95801 |
| 10,55433 | 11,71023 | 24,66311 | 1,880834 | -1,00879 | 0,068044 | 1,166505 |
| 4,641947 | -2,99846 | -14,5058 | -3,33552 | -5,936 | 3,420053 | 0,494968 |

| VARIÂNCIA EXPLICADA x | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 30,00693 | 85,87418 | 94,88131 | 96,29621 | 96,62578 | 96,89413 | 97,09019 |
| VALIDAÇÃO | 0 | 27,31793 | 77,91251 | 92,5537 | 94,49112 | 95,10764 | 95,22624 | 95,60179 |

| VARIÂNCIA EXPLICADA y | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 33,4261 | 42,48711 | 60,56204 | 69,88833 | 84,51084 | 90,73721 | 95,87817 |
| VALIDAÇÃO | 0 | 11,80559 | 29,79962 | 45,61076 | 52,74368 | 48,76849 | 44,6609 | 34,39459 |

| ERRO DA VALIDAÇÃO CRUZADA | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0,382386 | 0,311999 | 0,289991 | 0,240137 | 0,209831 | 0,150493 | 0,116378 | 0,077633 |
| VALIDAÇÃO | 0,389377 | 0,367633 | 0,325858 | 0,288077 | 0,271893 | 0,286876 | 0,296538 | 0,323667 |

## 5. MODELO V8 2015 – CAMPO (VER TALEBA 12)

| FATORES | | | | | | |
|---|---|---|---|---|---|---|
| FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| -17,1751 | 4,649762 | -0,16841 | -0,85196 | 1,09522 | -3,07956 | -2,43463 |
| 52,41691 | 0,51853 | -5,65568 | 5,016181 | -0,78309 | -0,0332 | -1,68259 |
| 27,74841 | 17,20339 | -1,32258 | 2,306258 | -0,23815 | 0,127448 | 2,633294 |
| 15,75706 | -22,2071 | 0,485201 | -6,28901 | -0,03352 | -0,33105 | 0,152575 |
| 6,648335 | 12,16759 | 5,422256 | 0,541449 | -2,20935 | -2,33602 | 1,845265 |
| 9,952237 | 3,787344 | 1,824365 | -8,38418 | -0,095 | -3,25513 | -0,93329 |
| -17,9371 | 33,3386 | -1,94193 | -8,50149 | -0,55514 | 5,290666 | -1,28252 |
| -15,7953 | -25,6061 | -0,17211 | -5,58076 | 1,217479 | 3,983161 | 0,195806 |
| 22,76701 | 12,37572 | -0,17834 | 15,41146 | 0,858484 | 0,336178 | 0,883046 |
| -24,5287 | -9,73201 | 2,551581 | 3,359338 | 1,313948 | -0,87105 | -1,09697 |
| -11,2489 | 43,29326 | 6,382574 | 3,040073 | 0,880805 | -1,42435 | 1,282738 |
| -12,1093 | 22,08202 | 2,345989 | 0,559411 | -0,61316 | 1,715344 | -1,01369 |
| 13,67728 | -12,4419 | 1,953211 | -1,86446 | -1,06048 | -1,19989 | 0,782869 |
| -26,4668 | 20,19272 | -4,49185 | 1,074044 | 0,037659 | -1,37838 | 2,673836 |
| 48,01934 | -8,32324 | 5,032301 | -2,04654 | 3,390553 | 0,993564 | 1,644413 |
| -8,52125 | -24,485 | 4,492223 | 2,391858 | -2,20602 | 1,751171 | -0,47129 |
| 11,22909 | -3,62115 | -0,44207 | 8,87889 | -3,90853 | 0,388933 | -2,27652 |
| 2,817483 | 32,24102 | -3,3477 | 7,448776 | -3,66676 | 1,279 | -0,31917 |
| -0,81493 | 25,12568 | 4,934764 | -6,11483 | 2,316312 | -0,16092 | -0,48112 |
| -13,1455 | -16,3606 | -9,13119 | -7,6056 | 0,162518 | 0,266476 | 1,316418 |
| 27,74841 | 17,20339 | -1,32258 | 2,306258 | -0,23815 | 0,127448 | 2,633294 |
| 10,46755 | -18,2446 | 1,525554 | 5,448409 | 0,3954 | 2,226949 | 3,153745 |
| -19,0522 | -42,1856 | 0,249101 | -12,5561 | -2,26774 | 0,028768 | 1,067924 |
| 12,78971 | 1,244044 | -1,41223 | 4,863297 | -0,73063 | -0,44509 | 0,729264 |
| 0,887426 | -29,9705 | 2,502914 | -4,95083 | 1,538555 | -0,17211 | 0,419636 |
| 6,789221 | 23,581 | -0,35744 | -2,89065 | 0,872171 | 2,82034 | -1,62529 |
| -46,1017 | 13,65189 | -5,14397 | -8,09149 | 0,168729 | -1,68434 | 0,717035 |
| -31,0078 | 20,58308 | 5,049418 | 4,009483 | -2,0985 | 0,610352 | -0,40209 |
| -24,5287 | -9,73201 | 2,551581 | 3,359338 | 1,313948 | -0,87105 | -1,09697 |
| -0,34142 | -13,2904 | 1,188584 | -7,69021 | -3,39451 | -2,33501 | -0,23187 |
| -8,77186 | 8,73231 | 0,321244 | -6,24595 | -1,03113 | 0,393162 | 0,958589 |

| | | | | | | |
|---|---|---|---|---|---|---|
| -12,7189 | -11,8694 | -1,4703 | 9,818957 | 0,785276 | -0,57478 | 1,397459 |
| -3,9876 | 27,34844 | 0,878465 | -5,83566 | 0,877782 | 2,65003 | -1,12964 |
| 33,74889 | -2,27215 | -1,39624 | -15,7088 | 3,682945 | 1,919755 | -2,24096 |
| -20,6349 | -11,2004 | -2,04171 | 7,47427 | 2,435236 | 0,992208 | 1,512673 |
| -18,7807 | -0,46212 | 0,431899 | 0,602906 | 0,628937 | -2,66717 | -0,46957 |
| 8,388602 | -7,9048 | -0,90035 | 2,080691 | -3,49821 | 0,490727 | -1,5359 |
| -25,5726 | -1,38295 | -4,42301 | 3,901637 | 1,939741 | 0,754947 | 2,264449 |
| 3,745899 | -14,2713 | 4,161102 | -4,20651 | -2,04627 | -0,51445 | 0,730072 |
| 0,555773 | -9,97369 | 0,142456 | 12,02616 | 2,078827 | -0,59116 | -3,83042 |
| 5,270982 | -11,459 | -5,19287 | 12,19051 | 1,143149 | -1,45064 | -0,22355 |
| 10,66573 | -8,65355 | -0,29711 | 0,04695 | -0,00363 | -1,10393 | -0,37304 |
| 16,56488 | 6,29043 | -4,9848 | -7,8315 | -3,82413 | -1,63307 | -2,33377 |
| -14,1435 | -24,0277 | -0,15782 | 8,696428 | 3,407185 | 0,014461 | -3,66119 |
| 18,82193 | 19,57342 | -1,11131 | -9,03685 | 2,772485 | -3,26829 | -0,60891 |
| -2,62816 | -26,3837 | 2,725839 | 5,194677 | -2,76197 | 2,716316 | 0,002582 |
| 9,748405 | -8,8209 | -0,76244 | -4,1293 | 0,953167 | -0,13454 | 2,695958 |
| -1,21371 | 9,698347 | 0,673424 | 4,364924 | 0,997551 | -0,36225 | 0,062034 |

| VARIÂNCIA EXPLICADA x | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 52,45881 | 90,62695 | 91,86596 | 97,71304 | 98,40715 | 99,25106 | 99,61679 |
| VALIDAÇÃO | 0 | 51,57842 | 90,1214 | 90,53812 | 96,97227 | 97,9889 | 98,84265 | 99,32095 |

| VARIÂNCIA EXPLICADA y | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 58,10838 | 73,93202 | 81,75075 | 81,96358 | 82,40829 | 82,78297 | 83,43859 |
| VALIDAÇÃO | 0 | 56,16171 | 71,73166 | 73,74112 | 76,44228 | 74,96167 | 73,54435 | 73,00185 |

| ERRO DA VALIDAÇÃO CRUZADA | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0,364728 | 0,236065 | 0,186218 | 0,155809 | 0,154897 | 0,152976 | 0,151338 | 0,148429 |
| VALIDAÇÃO | 0,376012 | 0,246976 | 0,198754 | 0,188493 | 0,17697 | 0,182268 | 0,186182 | 0,188668 |

## 6. MODELO R1 2015 – CAMPO (VER TALEBA 12)

| FATORES | | | | | | |
|---|---|---|---|---|---|---|
| FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| -11,7614 | 76,70145 | 2,245176 | 1,511722 | 0,268674 | -0,32638 | -0,9035 |
| -15,6894 | 24,52967 | -1,19744 | -2,8139 | -0,41917 | 0,82345 | -0,67299 |
| -20,6349 | -2,53647 | 0,692424 | -0,28964 | 0,202177 | 0,484117 | 0,474358 |
| -3,10328 | 15,91375 | 2,299781 | -1,09942 | -1,51469 | -1,31153 | 0,227032 |
| 2,598094 | 17,75479 | -0,98212 | 2,289653 | 1,306089 | -0,44736 | 0,771327 |
| -16,8608 | 26,55739 | -2,22412 | -6,56069 | -1,01103 | -0,98405 | 0,804286 |
| -3,35289 | 5,578132 | 3,989168 | -1,98204 | -2,44123 | -0,23733 | 0,347653 |
| -4,16121 | -6,01139 | -1,25956 | -2,88787 | 2,590198 | -0,07886 | -0,3649 |
| 19,39189 | -33,462 | 1,321761 | 1,997168 | 1,817639 | -1,24903 | 0,480075 |
| 11,93854 | -18,971 | 1,021418 | 0,913343 | 1,144263 | -1,55054 | 0,488714 |
| -20,1923 | -5,02952 | 7,309448 | -3,57403 | 1,496258 | 0,561798 | 0,33596 |
| 11,55763 | -15,2304 | 1,860717 | 7,634415 | 0,693715 | -0,29162 | 0,200411 |
| 10,27599 | 4,337637 | 7,163647 | -7,34466 | 0,881223 | 0,495015 | -0,34905 |
| -21,1484 | 25,92631 | 4,694713 | -6,94958 | 0,729232 | -0,98694 | 0,119597 |
| -13,5982 | -21,0913 | 0,681067 | 3,763289 | -1,15956 | -0,27315 | 0,795665 |
| 11,70446 | -21,6791 | 1,596069 | 6,07462 | 0,484996 | -0,45125 | 0,180433 |
| 9,629603 | -13,3009 | 3,382875 | -6,08108 | 0,536726 | -0,00061 | -0,77745 |
| -3,92387 | 8,051857 | -2,29527 | 4,568802 | 0,097201 | -0,46616 | 0,288982 |
| -2,09731 | -62,6607 | 2,262427 | -0,73057 | 0,880989 | 0,135509 | -0,46706 |
| -13,4069 | 7,846757 | 1,653913 | 6,353942 | 1,264278 | 2,206966 | -0,00515 |
| 16,58596 | 33,10218 | 3,15293 | 4,168343 | -1,06122 | 1,611419 | -0,90783 |
| 12,48478 | -9,06395 | -2,93194 | -6,06706 | 0,091864 | 1,242865 | 1,130186 |
| -8,59583 | 42,18016 | -5,81276 | 2,77279 | 0,659969 | -0,61526 | -1,52888 |
| 29,92693 | 50,91962 | 1,750478 | 2,056267 | -2,4965 | -1,26117 | 0,799984 |
| 6,288205 | 10,26906 | -5,80619 | -1,92082 | -0,29272 | -0,93797 | 1,822718 |
| 10,27499 | -16,8307 | 1,563548 | -6,9444 | 1,338737 | -3,35113 | -0,92031 |
| -2,2513 | 8,328157 | 0,31536 | 3,411906 | -0,76556 | -0,75123 | 0,015662 |
| -10,4867 | -15,5208 | 1,375998 | -1,29953 | -2,78171 | -2,09652 | 1,343869 |
| -8,38062 | -12,8587 | -0,3594 | 0,910861 | -1,72384 | 2,765289 | -0,2898 |
| 10,89127 | -1,96952 | 2,222893 | 1,770143 | -0,19469 | 1,898022 | -0,45459 |
| -10,3061 | -16,5153 | -1,09779 | -6,88266 | -2,44364 | -0,7493 | 0,116645 |

| | | | | | | |
|---|---|---|---|---|---|---|
| 15,33057 | -0,04587 | 3,517563 | 1,585013 | -0,33833 | -1,55004 | 0,197464 |
| -11,1261 | -31,2209 | -5,75475 | 10,69067 | -2,09559 | -2,47268 | -0,92539 |
| 7,630162 | 8,2832 | 1,68264 | 4,04905 | 0,268542 | -1,18851 | -0,00641 |
| -5,7148 | 5,592822 | -1,41751 | 4,493139 | 4,707246 | 1,485116 | 0,945922 |
| 6,391666 | 12,57085 | -9,89564 | -6,47874 | 3,947526 | -2,7608 | -1,18497 |
| 12,49395 | 5,677008 | -0,23794 | 2,089778 | -1,5944 | -0,0493 | -0,766 |
| -19,6175 | -27,6421 | -4,64006 | -7,1395 | -1,10702 | 1,973284 | -0,44247 |
| 25,05408 | -3,84999 | -6,95349 | -5,26386 | -0,6627 | 4,586665 | 1,025418 |
| -3,49066 | 26,11096 | 3,199194 | 2,787509 | 2,002294 | 1,830833 | -0,20396 |
| -16,7098 | -26,6618 | -0,01386 | 8,826123 | 0,462595 | 1,550207 | 0,247461 |
| 8,337809 | -27,4097 | 1,421443 | -3,95418 | -0,60979 | 2,854299 | -1,06299 |
| 9,657306 | 11,39987 | -3,99344 | 2,594541 | -2,85046 | 1,451447 | -1,72945 |
| -7,42265 | -43,3393 | -2,26102 | 3,200315 | -0,42266 | -1,46412 | -0,60769 |
| -4,43234 | 0,044069 | 0,783002 | 0,310732 | -2,40654 | -0,67548 | 0,24161 |
| -1,55836 | 11,67381 | -1,19981 | 3,391397 | 3,006669 | 0,518878 | 0,858626 |
| 9,306407 | -22,1202 | 1,492501 | -5,44929 | 0,364475 | -0,24842 | -0,99165 |
| 2,273406 | 15,67183 | -4,31805 | -2,50201 | -0,85055 | 0,351552 | 1,302387 |

| VARIÂNCIA EXPLICADA X | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 17,55161 | 93,83668 | 95,32781 | 98,65273 | 99,01204 | 99,40898 | 99,5726 |
| VALIDAÇÃO | 0 | -3,05655 | 93,18402 | 93,83772 | 97,88504 | 98,73369 | 99,09937 | 99,26001 |

| VARIÂNCIA EXPLICADA Y | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 79,36175 | 80,01582 | 85,67323 | 86,20199 | 88,02815 | 88,47195 | 89,42033 |
| VALIDAÇÃO | 0 | 63,16099 | 78,95879 | 82,50404 | 85,32624 | 83,9297 | 84,74514 | 84,20376 |

| ERRO DA VALIDAÇÃO CRUZADA | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0,359438 | 0,16329 | 0,160682 | 0,13605 | 0,133516 | 0,124367 | 0,12204 | 0,116912 |
| VALIDAÇÃO | 0,36609 | 0,225976 | 0,171867 | 0,158463 | 0,14528 | 0,153977 | 0,151433 | 0,154892 |

## 7. MODELO R3 2015 – CAMPO (VER TALEBA 12)

| FATORES | | | | | | |
|---|---|---|---|---|---|---|
| FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| -6,20949 | 10,50933 | 4,328193 | -1,1916 | 1,873961 | 0,118574 | -0,25207 |
| 5,529009 | 37,31377 | -1,64504 | 1,94714 | 1,679459 | -1,11849 | 1,174841 |
| 9,032513 | 28,7573 | 5,324193 | 0,221046 | 2,233569 | 2,261537 | 0,531843 |
| 14,94905 | -16,7662 | 7,04488 | -3,40204 | -1,6394 | 2,080451 | 2,110281 |
| 25,45313 | -11,0228 | -2,68974 | 1,851368 | 0,48475 | 0,325897 | -0,72162 |
| 17,21977 | -15,7816 | 3,287962 | -1,10128 | -0,17362 | -0,00435 | -0,29599 |
| -50,6724 | 12,81456 | 13,05024 | -12,1448 | -2,38649 | 0,98325 | 1,381151 |
| 5,191034 | -30,6395 | 0,521803 | 9,221916 | 3,166296 | -1,46411 | 2,182411 |
| 25,34766 | -1,05656 | 2,34744 | 2,807278 | -2,66735 | 1,235541 | -0,96171 |
| -14,7844 | -25,5511 | 8,313106 | 5,797513 | 2,203902 | 3,018885 | -1,748 |
| 0,384559 | 2,892455 | -1,49911 | 2,064357 | -0,78011 | -2,16919 | -0,42893 |
| 5,768977 | 3,56846 | -0,97125 | 1,165475 | -0,36083 | -1,15716 | -0,3046 |
| 19,63265 | -22,4276 | -1,92847 | 4,801239 | 1,900289 | -0,82095 | 0,313195 |
| -16,9543 | 29,77801 | -0,92264 | 2,725862 | -0,43548 | -0,67992 | -1,20168 |
| -2,09424 | 6,384475 | 1,532548 | -1,3942 | 1,970388 | 0,770053 | -0,09442 |
| 40,56428 | 3,434093 | 4,594275 | -5,71809 | 0,872669 | 3,090501 | 0,774415 |
| 14,31633 | 6,647936 | -2,76358 | -4,77697 | 0,329974 | 0,551116 | -2,4274 |
| 9,171716 | -39,0832 | 0,287738 | -12,8388 | 0,614308 | -4,54488 | 0,823922 |
| -5,1831 | 27,01348 | -21,5662 | -5,88603 | -1,25597 | 3,74062 | 0,608556 |
| -19,1147 | -6,47619 | 5,014524 | 6,166193 | -1,2824 | -1,51904 | 1,561245 |
| 3,838954 | 3,34087 | 0,495456 | 1,024701 | -2,3221 | -0,25829 | -0,64087 |
| -30,8302 | 25,47522 | 0,655869 | 4,508649 | 1,496448 | -0,79913 | -3,90331 |
| -8,75879 | -5,08909 | -4,97126 | -2,1436 | 1,39323 | -1,07237 | -0,84782 |
| -24,4886 | -16,4776 | -1,50116 | 1,336635 | -0,96255 | -0,32848 | -1,64092 |
| -37,8576 | -35,3663 | -10,4453 | 0,969092 | -0,05444 | 4,551027 | 2,330684 |
| -0,93012 | 30,21476 | 1,089932 | 3,676034 | -4,52094 | -3,01445 | 0,061325 |
| -2,88037 | 25,4734 | 4,590869 | -4,01571 | 4,987515 | 1,070029 | 1,274833 |
| 5,016083 | 26,03915 | 4,240757 | 1,031312 | -1,65411 | 0,076054 | 2,139457 |
| -19,1147 | -6,47619 | 5,014524 | 6,166193 | -1,2824 | -1,51904 | 1,561245 |
| 13,82581 | 9,535948 | 1,926396 | 1,276008 | -0,17433 | 1,011453 | -0,36777 |
| -20,0184 | -1,48049 | 1,00621 | -0,76457 | 3,671566 | 1,113792 | -4,03084 |

| | | | | | | |
|---|---|---|---|---|---|---|
| 20,20557 | 4,544929 | 0,758661 | -1,48223 | -0,92625 | -1,39833 | -0,18028 |
| -28,4861 | -20,9212 | -2,71538 | 3,567639 | -0,66842 | 1,515998 | 1,945966 |
| -23,5329 | -20,6167 | -5,94017 | 1,51955 | -0,00684 | 2,505707 | 1,484849 |
| -15,6791 | -17,1319 | -0,51039 | -6,60621 | -1,66174 | -2,75309 | -1,54673 |
| -2,28788 | -2,39904 | -3,86889 | 1,054944 | -0,54732 | -3,32578 | -0,24143 |
| -3,10622 | -0,07319 | -4,47802 | -3,77369 | -0,04299 | -2,52493 | 1,883876 |
| 4,573003 | -12,6973 | 4,802725 | 4,554445 | -3,16434 | 3,037474 | -1,00706 |
| 3,474753 | 32,98957 | 1,93695 | 1,059373 | -0,12038 | 2,609774 | -1,93442 |
| 21,06734 | -32,7119 | 1,415032 | 1,397988 | -1,01332 | -0,65806 | -0,55701 |
| -3,06984 | 2,44404 | -3,49368 | 3,104014 | 0,761886 | -4,08009 | -0,21699 |
| 24,39668 | 11,43715 | -5,32982 | -0,60924 | -0,85909 | 0,433799 | -1,48892 |
| 29,18456 | -9,92177 | 2,386999 | -1,97321 | -1,29758 | 2,596624 | 1,880355 |
| -3,07836 | 34,0808 | -2,50113 | 0,943068 | -2,3674 | -0,56069 | 1,499954 |
| -14,9621 | -20,7322 | 1,323994 | -8,63865 | 1,174488 | -1,09047 | -2,02565 |
| -1,3081 | -12,7045 | -1,52577 | 1,227317 | -1,04674 | 0,470078 | -1,46368 |
| 34,07428 | -14,2157 | -4,37874 | 0,380573 | 0,634283 | -0,17779 | -1,55601 |
| 3,184209 | 23,13 | -1,64559 | 0,894098 | 4,22589 | -2,12916 | 4,561782 |

| VARIÂNCIA EXPLICADA X | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 40,73408 | 91,05635 | 94,68298 | 97,4689 | 98,08754 | 99,08995 | 99,61767 |
| VALIDAÇÃO | 0 | 34,49842 | 89,16216 | 92,07319 | 96,46172 | 97,25334 | 98,42549 | 99,39803 |

| VARIÂNCIA EXPLICADA Y | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 49,25126 | 51,68094 | 57,61436 | 59,78857 | 63,89167 | 66,02449 | 70,01466 |
| VALIDAÇÃO | 0 | 41,24492 | 44,98819 | 44,52789 | 48,06703 | 45,26123 | 50,89172 | 44,48268 |

| ERRO DA VALIDAÇÃO CRUZADA | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0,352583 | 0,251174 | 0,245087 | 0,229547 | 0,223582 | 0,211868 | 0,205516 | 0,193071 |
| VALIDAÇÃO | 0,361463 | 0,272854 | 0,264204 | 0,265268 | 0,256287 | 0,264169 | 0,25084 | 0,270438 |

## 8. MODELO V8 2016 – CAMPO (VER TALEBA 12)

| FATORES | | | | | | |
|---|---|---|---|---|---|---|
| FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| -22,842 | -4,47918 | 2,348967 | 2,274075 | 1,260017 | -0,03184 | 0,288733 |
| -12,3062 | 7,844686 | 2,729476 | 2,356679 | -2,01569 | -0,51616 | -0,10332 |
| 4,189425 | 11,05012 | 1,725604 | -4,91475 | 0,21951 | 0,663249 | 0,331757 |
| 22,03968 | 1,733948 | 6,080603 | -1,07227 | -0,49541 | 0,620403 | 0,72847 |
| -19,8158 | -16,8001 | -5,59337 | 0,652927 | -0,86587 | 0,987037 | -0,35927 |
| 29,23951 | -6,26791 | 3,619987 | 4,235311 | 0,848896 | 0,139581 | -0,20467 |
| 10,80424 | 19,03134 | -2,01244 | 2,741472 | 0,375625 | 0,896061 | -0,23483 |
| 3,174805 | 7,738626 | -4,41304 | -1,16654 | 0,634627 | -1,12043 | -1,04564 |
| -36,5992 | -0,27879 | 9,230783 | 1,279645 | 0,064641 | -0,64597 | -0,29999 |
| -28,6406 | -4,40245 | 0,45257 | -2,02851 | -0,00068 | 0,083844 | 0,157654 |
| -22,7218 | -11,9596 | -1,95155 | -1,6548 | -0,07976 | 0,06198 | 0,320272 |
| 27,67808 | 1,906786 | 3,501256 | 2,794751 | 0,703559 | -0,2333 | -0,42396 |
| -4,62845 | -5,69759 | -2,2849 | -2,88273 | -1,21443 | 0,28111 | -0,55507 |
| -9,05022 | 4,467281 | -2,79182 | -2,69197 | 1,029168 | -0,40117 | 0,087105 |
| 24,90941 | 18,83241 | -4,93141 | -0,57856 | 0,452921 | 0,696321 | 0,946932 |
| 33,56652 | -54,2519 | 3,484471 | -2,45062 | 2,08458 | -0,26977 | -1,00994 |
| 6,315192 | 3,325589 | -8,03915 | 0,128942 | -0,13554 | -1,00079 | -0,82458 |
| -11,942 | 29,04747 | 0,955632 | -2,23238 | 1,595145 | 0,969635 | 0,936765 |
| 22,28367 | 12,09778 | -6,94126 | -5,01844 | -0,45673 | -0,80726 | 1,331718 |
| 26,61494 | -11,667 | -1,03483 | 0,180664 | -0,69047 | 1,09656 | -0,37872 |
| -22,2902 | 6,618024 | 5,077553 | 4,798167 | 0,809368 | -1,3869 | 1,287522 |
| 12,28827 | -1,89064 | 7,335242 | -0,99153 | -1,08786 | 0,055955 | 0,284932 |
| 4,218431 | 7,982637 | 5,673372 | -1,87463 | -1,37767 | -0,12663 | -0,24662 |
| -12,3339 | -9,61269 | -4,16469 | 2,968414 | 0,402455 | 0,043459 | -0,65149 |
| 22,34177 | 11,08478 | -1,3499 | -1,4419 | -0,42263 | -0,22719 | 0,152141 |
| -10,13 | 21,5464 | 1,001239 | -1,69509 | -0,32877 | -0,51082 | -2,03413 |
| 20,96861 | 9,950925 | -4,86618 | 9,722071 | -1,98394 | 0,315814 | 0,283084 |
| -11,2929 | -2,06345 | -3,06154 | 2,085533 | 0,324012 | -0,02299 | -0,60881 |
| -21,812 | -12,4672 | -2,77023 | 4,203688 | -0,74886 | 1,135868 | 0,09397 |
| 9,869938 | 32,03778 | -1,61305 | -0,68608 | 1,18532 | 0,703677 | 1,358484 |
| -1,87804 | 25,23359 | -3,00654 | -1,58569 | 0,627854 | -0,86459 | -0,45131 |

| | | | | | | |
|---|---|---|---|---|---|---|
| -15,0786 | -19,9956 | -5,64236 | -2,79033 | -0,4096 | -0,17266 | 0,481131 |
| -14,4265 | 3,397139 | 6,57337 | -0,66096 | -0,61936 | -0,36046 | 0,285681 |
| 10,11915 | 28,71204 | -4,77868 | -2,44753 | -0,24147 | -1,07985 | -0,71002 |
| 10,21831 | 2,278666 | 4,105461 | -4,34367 | 0,030106 | 0,468229 | 0,168835 |
| -16,7785 | -19,2353 | -4,46599 | -1,25653 | -0,01208 | 0,293645 | 0,769395 |
| -28,2706 | -10,4732 | -0,86024 | -0,19079 | 0,515973 | -0,09989 | 0,595528 |
| -16,0919 | -13,3797 | -4,84175 | 1,798314 | -0,24592 | 0,501201 | -0,52108 |
| 26,38738 | -18,9566 | 1,088791 | 3,928542 | 1,70446 | -0,40963 | 0,402491 |
| 42,13784 | -15,7538 | -4,45214 | 4,35819 | 0,053528 | -0,69622 | 0,092228 |
| 10,59476 | 14,19866 | 2,277011 | -2,735 | 0,17657 | 1,171274 | -2,12619 |
| -29,2491 | 1,178292 | 0,814753 | 0,007662 | 1,089162 | 0,842888 | -0,61678 |
| -32,4463 | -5,48696 | 4,197019 | 0,561148 | 0,332242 | -0,3027 | 0,224399 |
| 15,17721 | -8,46581 | 3,855252 | -0,04214 | -0,94866 | -0,42531 | 1,144081 |
| 2,494934 | -5,3916 | 8,509562 | -0,94883 | -1,639 | -0,47497 | -0,12207 |
| -7,47004 | -28,1156 | -9,31028 | -3,95599 | -0,73028 | -0,3052 | 0,772448 |
| 22,29966 | -14,9855 | 8,894364 | -3,31906 | -0,2538 | 0,268558 | 0,113073 |
| -11,8368 | 20,78318 | 1,64501 | 6,581054 | 0,484762 | 0,196381 | -0,11035 |

| VARIÂNCIA EXPLICADA X | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 67,13982 | 95,87207 | 98,28505 | 99,33176 | 99,59172 | 99,66336 | 99,76427 |
| VALIDAÇÃO | 0 | 63,77758 | 95,14265 | 97,75151 | 99,02207 | 99,38786 | 99,46759 | 99,59577 |

| VARIÂNCIA EXPLICADA Y | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0 | 39,56972 | 73,50812 | 81,34915 | 82,20719 | 82,74274 | 84,86998 | 85,89236 |
| VALIDAÇÃO | 0 | 34,18848 | 73,20004 | 79,67736 | 79,97655 | 76,44245 | 71,95571 | 73,20219 |

| ERRO DA VALIDAÇÃO CRUZADA | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | FATOR 0 | FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| CALIBRAÇÃO | 0,467763 | 0,363624 | 0,240759 | 0,202011 | 0,197309 | 0,194317 | 0,181947 | 0,175692 |
| VALIDAÇÃO | 0,478476 | 0,39059 | 0,256306 | 0,222683 | 0,22412 | 0,245275 | 0,267491 | 0,263702 |

## 9. MODELO R3 2016 – CAMPO (VER TALEBA 12)

| FATORES | | | | | | |
|---|---|---|---|---|---|---|
| FATOR 1 | FATOR 2 | FATOR 3 | FATOR 4 | FATOR 5 | FATOR 6 | FATOR 7 |
| -17,3631 | 8,098714 | -6,97171 | -8,21111 | -0,89983 | -2,65061 | -1,25996 |
| -2,95212 | 23,07323 | -1,83641 | -2,08799 | -3,76894 | 0,702089 | -1,35583 |
| -24,9437 | -11,8721 | -2,6562 | 0,705845 | -1,33219 | 1,359556 | 2,228764 |
| 11,36557 | -36,8435 | -1,8619 | -3,814 | -0,64606 | 0,222402 | 0,674802 |
| -16,8836 | 95,52412 | 0,010672 | 5,82262 | -0,30977 | 0,18213 | 3,420676 |
| 1,40388 | 40,3031 | 0,674417 | 0,286917 | 2,856246 | 0,869607 | -0,56794 |
| 19,31075 | 1,127581 | -1,15082 | -5,02648 | -0,88831 | -0,98283 | -0,84233 |
| 10,33941 | -13,5196 | 3,879858 | -1,09457 | -0,22957 | -0,19793 | -0,19951 |
| 2,565519 | 14,10706 | -0,13977 | -3,71717 | 3,616815 | 2,316857 | -0,77505 |
| -19,9603 | 14,13156 | 7,861844 | -9,58159 | 0,906617 | -0,00663 | -1,07896 |
| 2,094384 | -23,1056 | 3,744302 | -1,08265 | -0,14972 | 0,450989 | 1,690793 |
| 3,355341 | -11,1917 | -0,28283 | -1,95122 | 0,276937 | -0,49457 | 1,833417 |
| 4,720517 | -15,736 | -2,9753 | -5,03144 | -0,6822 | 0,019718 | 2,023291 |
| -17,2921 | -21,6483 | 6,010542 | 8,275157 | 0,232826 | -0,54624 | -4,01234 |
| -5,64473 | 7,729566 | 0,022901 | 1,308579 | -0,23993 | -0,13187 | 1,849552 |
| 13,20821 | -9,0067 | 3,784779 | 2,147714 | 0,255999 | -0,01519 | 0,402685 |
| -27,5703 | -6,77429 | -2,27426 | 2,812392 | -1,72709 | 0,927937 | -1,7985 |
| 18,52063 | -8,55168 | -1,7848 | 1,325572 | -0,54359 | -0,50077 | 0,749237 |
| 5,36135 | 27,0591 | -0,69988 | -5,39673 | 5,348893 | 2,853629 | -0,77098 |
| -14,8216 | -13,5865 | 1,113361 | 3,656883 | 0,062013 | 0,242577 | 0,715024 |
| 19,67262 | 2,314662 | -3,00063 | 0,887655 | -1,54742 | -0,3779 | 0,871577 |
| 7,978117 | 27,54296 | -0,22905 | -0,96164 | -4,11129 | 0,495784 | -2,96527 |
| 7,433589 | 42,05536 | 2,011666 | 2,905489 | 1,700392 | -1,64524 | -0,44784 |
| 7,746315 | -2,66147 | -3,08637 | 2,40483 | -2,24587 | -0,16151 | -0,34867 |
| 8,983398 | 24,44935 | -0,25749 | 6,682406 | -4,49503 | 1,523916 | -1,10476 |
| -7,05037 | -16,439 | 2,870215 | 3,216655 | 0,275575 | -0,49635 | -1,19363 |
| 4,64341 | 9,131459 | 1,344493 | 4,482828 | -0,54136 | 0,402076 | 0,142596 |
| -41,5157 | -24,2442 | -1,06168 | 3,25965 | 3,08593 | -1,69887 | 0,515426 |
| 17,57153 | -7,74279 | -6,18443 | 6,115075 | 4,910422 | 0,782316 | -0,72316 |
| -2,38426 | 10,73219 | -1,78952 | -7,57773 | 0,684683 | -1,87642 | -0,47534 |
| -3,54697 | 10,2149 | -0,75742 | 4,649036 | 0,772929 | -1,43817 | -0,10866 |

| | | | | | | |
|---|---|---|---|---|---|---|
| **6,994723** | **20,12873** | **0,032022** | **5,086752** | **3,591311** | **-3,53194** | **0,41711** |
| **4,689744** | **-4,8298** | **-0,70488** | **4,966012** | **-0,2201** | **-0,87835** | **-0,12015** |
| **-4,90221** | **-8,93481** | **0,200443** | **-2,58568** | **-0,49373** | **-0,12986** | **0,217328** |
| **4,530636** | **-31,3012** | **2,228218** | **3,868593** | **-2,03434** | **0,408728** | **-0,01855** |
| **15,08837** | **2,891617** | **2,091577** | **-2,26232** | **-0,85614** | **-0,01746** | **0,002649** |
| **10,15057** | **-9,71226** | **3,280843** | **-0,37168** | **-0,09347** | **0,399522** | **1,334659** |
| **21,55348** | **-16,7658** | **1,726711** | **-0,0026** | **0,179141** | **-0,80358** | **1,311314** |
| **-4,98788** | **-8,53887** | **-3,91656** | **-1,75364** | **-0,94233** | **-1,06366** | **-2,06253** |
| **12,34866** | **20,93712** | **-0,52245** | **-0,77546** | **-3,16841** | **0,591188** | **-0,0482** |
| **3,744855** | **-27,6548** | **-4,72688** | **2,288372** | **3,586231** | **2,096339** | **-1,28006** |
| **13,33012** | **-21,1008** | **0,391004** | **0,797901** | **0,187596** | **-0,59487** | **0,526754** |
| **-5,19211** | **-8,2296** | **1,80064** | **0,771469** | **-0,95024** | **0,598486** | **-0,06064** |
| **-4,51813** | **-9,2541** | **4,14269** | **-3,59482** | **-0,26974** | **0,510722** | **2,062702** |
| **-31,6117** | **-8,81572** | **-2,38944** | **-2,6963** | **-2,19841** | **1,363257** | **1,488186** |
| **0,159857** | **1,361884** | **0,217145** | **-1,95701** | **1,829747** | **1,602319** | **-0,90127** |
| **0,486896** | **6,464339** | **2,65003** | **-9,7933** | **0,742569** | **-0,97993** | **-0,80726** |
| **-6,21161** | **-31,3172** | **-0,82973** | **2,602715** | **0,482233** | **0,298613** | **0,848863** |

| **VARIÂNCIA EXPLICADA X** | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | **FATOR 0** | **FATOR 1** | **FATOR 2** | **FATOR 3** | **FATOR 4** | **FATOR 5** | **FATOR 6** | **FATOR 7** |
| CALIBRAÇÃO | 0 | 37,9829 | 94,70164 | 96,11552 | 98,38117 | 98,99496 | 99,4054 | 99,65656 |
| VALIDAÇÃO | 0 | 47,57714 | 93,85725 | 94,8858 | 97,90095 | 98,57038 | 99,04507 | 99,50746 |

| **VARIÂNCIA EXPLICADA Y** | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | **FATOR 0** | **FATOR 1** | **FATOR 2** | **FATOR 3** | **FATOR 4** | **FATOR 5** | **FATOR 6** | **FATOR 7** |
| CALIBRAÇÃO | 0 | 54,45811 | 71,13882 | 78,05856 | 79,99532 | 81,58556 | 83,15186 | 85,14925 |
| VALIDAÇÃO | 0 | 37,92283 | 69,06868 | 67,52011 | 73,54815 | 72,98323 | 73,39611 | 72,40613 |

| **ERRO DA VALIDAÇÃO CRUZADA** | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| | **FATOR 0** | **FATOR 1** | **FATOR 2** | **FATOR 3** | **FATOR 4** | **FATOR 5** | **FATOR 6** | **FATOR 7** |
| CALIBRAÇÃO | 0,343789 | 0,232005 | 0,184692 | 0,161037 | 0,153765 | 0,147527 | 0,141113 | 0,132485 |
| VALIDAÇÃO | 0,352561 | 0,27501 | 0,198457 | 0,199914 | 0,182864 | 0,183997 | 0,183716 | 0,187818 |