

UNIVERSIDADE ESTADUAL DE MARINGÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE AGRONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

KARYM MAYARA DE OLIVEIRA

Dados multi e hiperespectrais da cultura do milho segunda safra cultivado sob diferentes fontes e doses de fósforo

Maringá-PR

2020

KARYM MAYARA DE OLIVEIRA

Dados multi e hiperespectrais da cultura do milho segunda safra cultivado sob diferentes fontes e doses de fósforo

Dissertação apresentada ao Programa de Pós-Graduação em Agronomia do Departamento de Ciências Agrárias da Universidade Estadual de Maringá, como requisito parcial para a obtenção do título de Mestre em Agronomia.

Área de concentração: Solos e Nutrição de Plantas.

Orientador: Prof. Dr. Marcos Rafael Nanni.

Maringá-PR

2020

Dados Internacionais de Catalogação-na-Publicação (CIP)
(Biblioteca Central - UEM, Maringá - PR, Brasil)

O48d

Oliveira, Karym Mayara de

Dados multi e hiperespectrais da cultura do milho segunda safra cultivado sob diferentes fontes e doses de fósforo / Karym Mayara de Oliveira. -- Maringá, PR, 2020.
xiv, 95 f.: il. color., figs., tabs.

Orientador: Prof. Dr. Marcos Rafael Nanni.

Dissertação (Mestrado) - Universidade Estadual de Maringá, Centro de Ciências Agrárias, Departamento de Agronomia, Programa de Pós-Graduação em Agronomia, 2020.

1. Milho - Cultura. 2. Milho - Adubo fosfatado. 3. Sensoriamento remoto - Agricultura. 4. Espectrorradiometria. 5. Análise multivariada. I. Nanni, Marcos Rafael, orient. II. Universidade Estadual de Maringá. Centro de Ciências Agrárias. Departamento de Agronomia. Programa de Pós-Graduação em Agronomia. III. Título.

CDD 23.ed. 633.15

FOLHA DE APROVAÇÃO

KARYM MAYARA DE OLIVEIRA

Dados multi e hiperespectrais da cultura do milho segunda safra cultivado sob diferentes fontes e doses de fósforo

Dissertação apresentada ao programa de Pós-Graduação em Agronomia do Departamento de Agronomia, Centro de Ciências Agrárias da Universidade Estadual de Maringá, como requisito parcial para obtenção do título de Mestre em Agronomia:

fevereiro de 2020

COMISSÃO JULGADORA

Prof. Dr. Marcos Rafael Nanni
(Presidente) Universidade Estadual de Maringá - UEM

Prof. Dr. Marcelo Augusto Batista
Universidade Estadual de Maringá - UEM

Prof. Dr^a. Lucimar Pereira Bonett
Universidade Paranaense - UNIPAR.

Local da defesa: Universidade Estadual de Maringá, bloco J45, Anfiteatro I, Maringá-PR

AGRADECIMENTOS

Agradeço a Deus pela vida, saúde e pela maravilhosa família que me deu.

Agradeço aos meus pais, Elaine e Nelcides, meus irmãos Keyla e Nelcides Junior e meu amado companheiro Rodrigo Horst pelo amor, incentivo, paciência e força diária. Minha família representa o forte alicerce de todas as minhas conquistas.

Aos irmãos e irmãs que escolhi para a vida: Eduarda Patrícia de Moraes, Solange Caetano, Wanderson Almeida, Neuzilene Rossi e Raquel Sevilha. E aos amigos (as) Carlos Henrique Braga, Amanda Amorin, Ivan Paschoalotto, Maico Huss, Leila Canton e Alessandra Vollmann, pelo companheirismo e risadas.

Ao meu orientador Marcos Rafael Nanni, agradeço pelos ensinamentos, conselhos, direcionamentos e companheirismo.

Agradeço aos meus colegas e companheiros de trabalho do GALeS UEM, em especial ao Renato Furlanetto, Marlon Rodrigues, Glaucio Lebosso, Amanda Reis, Luis Crusiol e Anderson Gonçalves pela ajuda no desenvolvimento deste trabalho, tanto em campo como intelectual.

Agradeço à Coamo pela disponibilização da área experimental, bem como pelo auxílio na instalação e condução do experimento. Aos colegas do grupo GESSO UEM, em especial ao Marcos Besen, Evandro Minato e Eder Zampar e ao Professor Marcelo Augusto Batista, pela parceria e direcionamentos durante a instalação e execução deste trabalho.

Para minhas colegas Érika Sato e Sílvia Tanno e meus colegas Roberto Carlos e Reinaldo, agradeço pela companhia e disposição sempre que necessário.

Ao programa de Pós-graduação em Agronomia.

À todos que contribuíram para a realização deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

EPÍGRAFE

*Sem sonhos, a vida não tem brilho.
Sem metas, os sonhos não têm alicerces.
Sem prioridades, os sonhos não se tornam reais.
Sonhe, trace metas, estabeleça prioridades e
corra riscos para executar seus sonhos.
Melhor é errar por tentar do que errar por omitir.*

Augusto Cury

RESUMO

OLIVEIRA, K. M., Me. Universidade Estadual de Maringá (UEM), fevereiro de 2020. **Dados multi e hiperespectrais da cultura do milho segunda safra cultivado sob diferentes fontes e doses de fósforo.** Orientador: Prof. Dr. Marcos Rafael Nanni.

O sensoriamento remoto tem ganho destaque na agricultura, uma vez que suas técnicas e modelagem de dados têm sido aplicadas com o intuito de detectar deficiências nutricionais em plantas a partir de seu espectro de reflectância, coletado por sensores multiespectrais e hiperespectrais, além de gerar estimativas de parâmetros biofísicos de culturas. A utilização de veículo aéreo não tripulado (VANT) como ferramenta de monitoramento de lavouras e coleta de dados têm sido mundialmente reconhecida, os avanços recentes na tecnologia computacional, desenvolvimento de software, materiais mais leves, sistemas globais de navegação, sofisticados sensores e a miniaturização estão entre os motivos do crescente uso desta ferramenta tanto no Brasil, como no mundo. O objetivo deste trabalho foi avaliar aplicações e caracterizar dados espectrais da cultura de milho segunda safra cultivado sob diferentes doses de adubo fosfatado, a partir da coleta destes dados com os sensores hiperespectral a nível de campo e câmeras multiespectrais acopladas a VANT. Foram realizados dois experimentos em delineamento de blocos casualizados (DBC), constituído por cinco tratamentos, compostos por diferentes doses de adubo fosfatado (0, 30, 60, 120 e 240 kg ha⁻¹ P₂O₅) e quatro repetições, aplicados em cultura de milho segunda safra. Os experimentos foram diferenciados pela fonte de adubo fosfatado utilizada (monoamônio fosfato para experimento 1 e superfosfato simples para o experimento 2). Os tratamentos foram aplicados no sulco de plantio e utilizado o sistema de plantio direto. Os dados espectrais foram coletados pelo espectrorradiômetro Fieldspec 3 Jr., aos 30, 37, 53, 66, 73, 80, 92 e 99 DAE e pelas câmeras multiespectrais aos 37, 53, 66, 73, 80 e 92 DAE. Foram avaliados a caracterização da curva espectral do milho a partir dos tratamentos aplicados; desempenho dos índices de vegetação NDVI, GNDVI, RNIR, GNIR, RVI e GRVI, na distinção dos diferentes níveis nutricionais impostos a cultura; modelos discriminantes lineares elaborados a partir dos dados espectrais obtidos pelo espectrorradiômetro na discriminação e classificação de indivíduos; e modelos de PLSR elaborados a partir dos dados espectrais obtidos pelo espectrorradiômetro na predição de fósforo foliar e produtividade da cultura. A partir dos resultados obtidos, pôde-se concluir que o comportamento espectral da cultura de milho segunda safra apresenta diferenças de acordo

com os níveis de nutrição da planta promovidos por adubo fosfatado, no qual é possível distinguir plantas sob severa deficiência nutricional de fósforo das plantas bem nutridas por doses maiores do fertilizante; quanto a utilização da técnica multivariada de análise discriminante linear, o modelo apresentou boa qualidade, caracterizada por um erro médio condizente as particularidades da interação do fertilizante com solo e planta; já os índices de vegetação demonstraram habilidade para distinguir tratamentos com deficiência nutricional dos tratamentos cujas planta encontravam-se bem nutridas, porém, pouca sensibilidade para diferenciar os tratamentos compostos maiores doses de adubo; a modelagem dos dados de reflectância espectral, a partir da técnica PLSR, apresentaram potencial para predição de fósforo foliar e produtividade.

Palavras-chave: Análise multivariada, Espectrorradiometria, Sensoriamento remoto.

SUMMARY

OLIVEIRA, K. M., M.Sc. Maringá State University (UEM), February 2020.
Multi and hyperspectral data of second-crop corn cultivated under different sources and doses of phosphorus Adviser: Prof. Dr. Marcos Rafael Nanni.

Remote sensing has highlighted in agriculture, since its techniques and data modeling were applied in order to detect plants nutritional deficiencies from their reflectivity spectrum, collected by multispectral and hyperspectral sensors, besides its generate estimate crops biophysical parameters. The use of unmanned aerial vehicle (UAV) as a tool for crop monitoring and data collection, have been recognized worldwide, recent advances in computing technology, software development, lighter materials, global navigation systems, sophisticated sensors and miniaturization are among the reasons for the growing use of this tool in Brazil and other counties. The objective of this work was to evaluate applications and characterize spectral data of second-crop corn cultivated in different phosphate fertilizer doses, from this data collection with field-level hyperspectral sensors and multispectral cameras coupled to UAV. Two experiments were carried out in randomized block design (RBD), consisting of five treatments, composed of different phosphate fertilizer doses (0, 30, 60, 120 e 240 kg ha⁻¹ P₂O₅), and four repetitions, applied to corn. The experiments were differentiated by the phosphate fertilizer source used (monoammonium phosphate for experiment 1 and simple superphosphate for experiment 2). The treatments were applied in the planting furrow and was used the no-till system. Spectral data were collected by the Fieldspec 3 Jr. spectroradiometer at 30, 37, 53, 66, 73, 80, 92 and 99 DAE and by multispectral cameras at 37, 53, 66, 73, 80 and 92 DAE. The spectral curve characterization of corn was evaluated from the treatments applied; performance of NDVI, GNDVI, RNIR, GNIR, RVI and GRVI vegetation indices, in distinguishing the different nutritional levels imposed on culture; linear discriminant models elaborated from the spectral data obtained by the spectroradiometer in the discrimination and classification of individuals; and PLSR models elaborated from spectral data obtained by spectroradiometer in the prediction of leaf phosphorus and crop productivity. From the results obtained, it was concluded that the spectral behavior of the second-crop corn differs according to the plant nutrition levels promoted by phosphate fertilizer, where it is possible to distinguish plants under severe nutritional phosphorus deficiency from plants well nourished by higher doses of fertilizer; regarding the use of the multivariate technique of linear discriminant analysis, the

model showed good quality, characterized by a medium error consistent with the particularities of the fertilizer interaction with soil and plant; the vegetation indexes demonstrated the ability to distinguish treatments with nutritional deficiency from treatments whose plants were well nourished, however, the modeling of spectral reflectance data, using the PLSR technique, showed potential for predicting leaf phosphorus and productivity.

Keywords: Multivariate analysis, Spectroradiometry, Remote sensing.

LISTA DE TABELAS

Tabela 1. Caracterização dos estádios fenológicos para a cultura de milho. (Adaptado de Ritchie e Hanway, 1989).....	7
Tabela 2. Fontes e doses de fósforo aplicadas nos tratamentos.....	24
Tabela 3. Características químicas do solo antes da instalação do experimento.....	25
Tabela 4. Índices de vegetação utilizados neste trabalho.....	31
Tabela 5. Bandas espectrais selecionadas para participação na construção de modelos discriminantes lineares a partir de curvas espectrais de milho em função de doses de adubo fosfatado MAP, obtidas pelo espectrorradiômetro.....	48
Tabela 6. Coeficientes dos modelos discriminantes lineares.....	49
Tabela 7. Quadrado da distância generalizada entre as médias.....	50
Tabela 8. Estimativa de erro para cada tratamento reclassificado pela análise discriminante.....	52
Tabela 9. Bandas selecionadas para participação na construção de modelos discriminantes lineares a partir de curvas espectrais de milho, obtidas pelo espectrorradiômetro em função de doses do adubo fosfatado SS.....	54
Tabela 10. Coeficientes dos modelos discriminantes lineares.....	56
Tabela 11. Quadrado da distância generalizada entre as médias.....	56
Tabela 12. Estimativa de erro para cada tratamento reclassificado pela análise discriminante.....	57
Tabela 13. Teste de comparação de médias dos IV's obtidos por meio do espectrorradiômetro em diferentes datas de avaliação, para o experimento com adubo fosfatado MAP.....	61
Tabela 14. Teste de comparação de médias dos IV's obtidos por meio do espectrorradiômetro em diferentes datas de avaliação, para o experimento com adubo fosfatado SS.....	63
Tabela 15. Teste de comparação de médias dos IV's obtidos por meio de imagens aéreas em diferentes datas de avaliação, para o experimento com adubo fosfatado MAP.....	65

Tabela 16. Parâmetros estatísticos do modelo PLSR para estimativa do teor de P foliar em cultura de milho.....	69
Tabela 17. Valores de referência do teor de P foliar e valores estimados pelo modelo PLSR.....	71
Tabela 18. Parâmetros estatísticos do modelo PLSR para estimativa de produtividade em diferentes estádios fenológicos na cultura de milho.....	75
Tabela 19. Valores de referência de produtividade e valores estimados pelo modelo PLSR, para milho em estágio V6.....	77
Tabela 20. Teste de normalidade de desvios e homogeneidade de variâncias para os índices de vegetação obtidos em função de diferentes doses do adubo fosfatado MAP, por meio do espectrorradiômetro.....	92
Tabela 21. Teste de normalidade de desvios e homogeneidade de variâncias para os índices de vegetação obtidos em função de diferentes doses do adubo fosfatado SS, por meio do espectrorradiômetro.....	93
Tabela 22. Teste de normalidade de desvios e homogeneidade de variâncias para os índices de vegetação obtidos em função de diferentes doses do adubo fosfatado MAP, por meio de câmeras digitais.....	94
Tabela 23. Teste de normalidade de desvios e homogeneidade de variâncias para os índices de vegetação obtidos em função de diferentes doses do adubo fosfatado SS, por meio de câmeras digitais.....	95

LISTA DE FIGURAS

Figura 1. Representação de gráficos gerados a partir de dados espectrais coletados de plantas de milho. A) Dados multiespectrais com quatro bandas (R-G-B e NIR); B) Dados hiperespectrais com 600 bandas.....	12
Figura 2. Comportamento espectral característico de vegetação sadia. Adaptado de Novo (1989).....	16
Figura 3. Índices de vegetação aplicados a imagens. A) Original; B) NDVI; C) GNDVI.....	18
Figura 4. Fluxograma da metodologia e materiais utilizados no trabalho.....	23
Figura 5. Dados de temperatura média (°C) e precipitação (mm) dos decênios mensais de novembro de 2018 a junho de 2019.....	24
Figura 6. Esquema de trabalho a campo com o espectrorradiômetro.....	26
Figura 7. Exemplo de utilização do ASD Plant probe.....	27
Figura 8. Câmera fotográfica multiespectral Fujifilm S200-EXR.....	28
Figura 9. Veículo aéreo não tripulado utilizado para transporte das câmeras.....	29
Figura 10. Análise de regressão para teores de P no solo em função dos insumos aplicados. A: parcelas com utilização de adubo fosfatado MAP (Monoamônio Fosfato); B: parcelas com utilização de adubo fosfatado SS (Superfosfato Simples). Doses de 0, 30, 60, 120, 240 kg ha ⁻¹ P ₂ O ₅ referente aos tratamentos T1, T2, T3, T4, T5, respectivamente, para ambos os adubos).....	37
Figura 11. Fator de reflectância médio dos tratamentos, obtido por espectrorradiômetro na cultura de milho em diferentes estádios de desenvolvimento, referente ao experimento com fertilizante fosfatado MAP.....	40
Figura 12. Desenvolvimento da cultura de milho safrinha em função de diferentes níveis do adubo fosfatado MAP. A: 60 kg ha ⁻¹ P ₂ O ₅ ; B: 0 kg ha ⁻¹ P ₂ O ₅ ; C: 240 kg ha ⁻¹ P ₂ O ₅	43
Figura 13. Fator de reflectância médio dos tratamentos, obtido por espectrorradiômetro na cultura de milho em diferentes estádios de desenvolvimento, referente ao experimento com fertilizante fosfatado SS.....	45

Figura 14. Análise discriminante linear do conjunto de dados referente ao adubo MAP. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 100% dos dados que compõem o modelo.....	51
Figura 15. Análise discriminante linear do conjunto de dados referente ao adubo MAP. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 60% dos dados que compõem o modelo.....	52
Figura 16. Análise discriminante linear do conjunto de dados referente ao adubo MAP. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 40% dos dados que compõem o modelo.....	53
Figura 17. Análise discriminante linear do conjunto de dados referente ao adubo SS. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 100% dos dados que compõem o modelo.....	57
Figura 18. Análise discriminante linear do conjunto de dados referente ao adubo MAP. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 60% dos dados que compõem o modelo.....	58
Figura 19. Análise discriminante linear do conjunto de dados referente ao adubo SS. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 40% dos dados que compõem o modelo.....	58
Figura 20. Coeficientes do modelo de regressão PLSR para predição do teor de P foliar.....	72
Figura 21. Produtividade da cultura de milho segunda safra sob diferentes fontes e doses de adubo fosfatado; Monoamônio fosfato (A) e superfosfato simples (B). T1, T2, T3, T4 e T5 (0, 30, 60, 120 e 240 kg ha ⁻¹ P ₂ O ₅ , respectivamente). *Médias seguidas pela mesma letra na coluna não diferem estatisticamente entre si pelo teste t a 5% de probabilidade de erro.....	73
Figura 22. Coeficientes do modelo de regressão PLSR para predição de produtividade.....	78

LISTA DE ABREVIACOES

CCD - Charge Coupled Device

DAE - Dias Aps Emergncia

DN - Digital Number

GNDVI - Índice de Vegetao da Diferena de Verde Normalizado

GNIR - Razo entre o verde e o infravermelho prximo

GRVI - Razo entre infravermelho prximo e o verde

IV's - Índices de Vegetao

MAP - Monoamnio Fosfato

NDVI - Índice de Vegetao da Diferena Normalizado

NIR - Near Infrared

PLSR - Partial Least Square Regression

REM - Radiao eletromagntica

RGB - Red Green Blue

RMSE - Root Mean Square Error

RNIR - Razo entre o vermelho e o infravermelho prximo

ROI - Region of Interest

RVI - Razo entre o infravermelho prximo e vermelho

SAVI - Índice de Vegetao Ajustador do Solo

SEP - Standard Error of Performance

SS - Superfosfato Simples

SWIR - Infravermelho de ondas curtas

VANT - Veículo Areo No Tripulado

VAR - Veículo Areo Remotamente Controlado

SUMÁRIO

1. INTRODUÇÃO.....	1
2. OBJETIVO GERAL	4
2.1. Objetivos específicos	4
3. REVISÃO DE LITERATURA.....	5
3.1. Aspectos gerais sobre a cultura do milho	5
3.1.1. Importância econômica	5
3.1.2. Características da planta	6
3.1.3. Importância do fósforo para cultura	7
3.2. Fertilizantes fosfatados	9
3.3. Sensoriamento remoto aplicado a agricultura	10
3.3.1. Conceito geral e princípio	10
3.3.2. Tipos de sensores e níveis de aquisição de dados	11
3.3.3. Comportamento espectral da vegetação	14
3.3.4. Índices de vegetação (IV's)	17
3.4. Utilização de VANT no monitoramento agrícola	18
3.5. Estatística multivariada aplicada ao estudo de parâmetros agrônômicos	20
4. MATERIAL E MÉTODOS	23
4.1. Descrição geral da área de estudo	23
4.1.1. Caracterização do município e da área experimental	23
4.2. Implantação do experimento	24
4.3. Coleta de dados espectrorradiométricos	26
4.3.1. Coleta de dados com espectrorradiômetro	26
4.3.2. Coleta de dados com a câmera fotográfica multiespectral e conversão para reflectância	28
4.3.3. Processamento das imagens aéreas	30
4.4. Obtenção dos índices de vegetação	31
4.5. Períodos de avaliações	32
4.6. Análise foliar nutricional	32
4.7. Análise de solo	33
4.8. Obtenção de dados de produtividade	33
4.9. Análise estatística multivariada	33
4.9.1. Modelos lineares discriminantes	33
4.9.2. Análise de regressão pelo método dos mínimos quadrados parciais (PLSR).....	35
5. RESULTADOS E DISCUSSÃO.....	37
5.1. Teor de fósforo no solo	37
5.2. Comportamento espectral do milho sob diferentes doses de P e datas de avaliações	39
5.3. Funções discriminantes elaboradas a partir de dados espectrais coletados pelo espectrorradiômetro	47

5.4. Avaliação da relação entre índices de vegetação (IV's) e doses de adubo fosfatado	59
5.4.1. Índices de vegetação obtidos por espectrorradiômetro	59
5.4.2. Índices de vegetação obtidos por câmeras digitais	64
5.5. Modelo de predição para fósforo foliar utilizando Partial Least Square Regression (PLSR) a partir de dados obtidos pelo espectrorradiômetro.....	68
5.6. Análise e modelos de predição dos dados de produtividade	72
5.6.1. Relação entre dados de produtividade e curvas espectrais	73
5.6.2. Modelos de predição de produtividade utilizando Partial Least Square Regression (PLSR)	74
6. CONCLUSÕES	79
7. REFERÊNCIAS BIBLOGRÁFICAS	80
APÊNDICE A	92
APÊNDICE B	94

1. INTRODUÇÃO

No cenário agrícola atual brasileiro, tem-se observado contínuo aumento da produção de culturas, com produtividade de grãos estimada em 246,6 milhões de toneladas para a safra 2019/2020, representando aumento de 1,9% em relação à safra anterior (CONAB, 2019). O aumento de área plantada, bem como eficiência de práticas agrícolas e desenvolvimento tecnológico tem sido fatores de grande influência para esse desenvolvimento.

Atualmente, um dos fatores que representam maior custo para o agricultor é o uso de insumos, como os fertilizantes (Guareschi et al., 2008), tornando importante o conhecimento das características do solo e cultura com o qual se trabalha para que não haja gastos desnecessários. A produção agrícola em busca de produtividade crescente, exige o uso de corretivos e fertilizantes em quantidades adequadas, de forma a conciliar resultado econômico positivo e produtividade, bem como preservação dos recursos naturais e meio ambiente (RAIJ, 2011).

O efeito benéfico da adição de elementos minerais aos solos para melhorar o crescimento das plantas é conhecido na agricultura há mais de 2.000 anos (MARSCHNER, 2012). Para um elemento ser considerado essencial, três critérios devem ser atendidos: uma determinada planta deve ser incapaz de completar seu ciclo de vida na ausência do elemento; a função do elemento não deve ser substituível por outro elemento; o elemento deve estar diretamente envolvido no metabolismo da planta ou alguma etapa metabólica distinta, como uma reação enzimática (ARNON e STOUT, 1939).

A deficiência de fósforo (P) é comum na maioria dos solos brasileiros. Segundo Raij (2011) é também um nutriente que tem como particularidade o alto grau de interação com o solo, e essa característica associada à sua deficiência em vastas áreas da agricultura brasileira, fez desse elemento um dos mais críticos nas adubações nas últimas décadas.

O P tem funções importantes na planta, como constituinte de compostos de alta energia, como ATP (Adenosina Trifosfato), derivados do inositol (fitinas), fosfolípidios e outros ésteres (Ventimiglia et al., 1999), assim, sua disponibilidade na solução do solo é fundamental para suprir as necessidades das plantas, resultando em altos rendimentos. Mas mesmo quando aplicada a dose recomendada para as necessidades da cultura, muitas vezes nem todo adubo se encontra disponível para a planta devido a interações com o solo, e muitas vezes a deficiência não é significativamente severa a ponto de mostrar os sintomas na folha (denominado fome oculta) que então só é notada a partir de baixos valores na produtividade, gerando prejuízo ao agricultor.

O sensoriamento remoto tem ganho destaque na agricultura. Este é definido como uma tecnologia que permite obter imagens e outros tipos de dados da superfície terrestre e de objetos, por meio da captação e do registro da energia refletida (reflectância) ou emitida por sua superfície (radiância) (FLORENZANO, 2011).

Técnicas de sensoriamento remoto têm sido utilizadas, aplicadas à agricultura, na tentativa de detectar deficiências nutricionais em plantas a partir de seu espectro de reflectância, coletado por sensores multiespectrais e hiperespectrais. O método tem se demonstrado promissor principalmente pela ausência de necessidade de coletar amostras (método não destrutivo), além de contribuir para menor custo e maior rapidez de execução dos levantamentos de dados (Pinheiro et al., 2013), permitindo tempo hábil para correção de condições prejudiciais a produtividade.

Esta técnica permite, por intermédio de uma análise da distribuição espacial das áreas plantadas e mapeamento das diferenças do vigor da cultura, ou seja, das diferenças espectrais dos alvos, avaliar o potencial de produção da área cultivada (DELGADO et al., 2013).

De acordo com Epiphany et al. (1996), tem-se conseguido, com determinadas espécies, importantes relacionamentos entre propriedades espectrais e propriedades biofísicas, tais como: índice de área foliar, fitomassa, percentagem de cobertura do solo, concentração de clorofila e fração da radiação fotossinteticamente ativa absorvida pelo dossel.

Osborne et al. (2002) trabalhando com doses de fósforo e nitrogênio em cultura de milho, observaram que dados hiperespectrais podem ser usados para estimar a concentração de P, biomassa e rendimento de grãos na cultura sob a presença de estresse nutricional, tendo sua melhor predição nos estádios vegetativos iniciais entre V6 e V8. Estes mesmos autores citam que a utilização de técnicas de sensoriamento remoto para estimar status nutricional de plantas pode diminuir a quantidade de mão de obra necessária para amostragem e, portanto, contribuir na diminuição de seu custo, além de ser um método não destrutivo para as plantas.

Segundo Silva Junior et al. (2007), as aplicações de sensoriamento remoto no estudo de culturas agrícolas têm feito uso extensivo dos índices de vegetação, para avaliar a reflectância do dossel de culturas. Estes ainda verificaram em seu trabalho que o sistema de sensoriamento remoto foi capaz de detectar os diferentes níveis nutricionais em forrageira, demonstrando boa relação entre os índices e os valores estimados do teor de clorofila.

Zhang e He (2013), analisando o comportamento espectral da cultura de colza sob diferentes doses de N, P e K, elaboraram, por meio de análise multivariada, um modelo matemático para predição de produtividade a partir das respostas espectrais da cultura.

Deficiências ou excessos de nutrientes podem afetar a cor, conteúdo de umidade e estrutura interna de folhas e, como resultado, mudará também o poder de reflexão. Assim, as medidas de reflectância das folhas de plantas em desenvolvimento demonstra-se como uma técnica não destrutiva promissora, pelas quais mudanças na estrutura, pigmentação e conteúdo de umidade que são induzidas nas plantas pelas mudanças no ambiente, podem ser detectadas (FREIRE, 2004). Contudo, deve-se ter conhecimento sobre técnicas de calibração dos sensores e processamento de dados para obtenção de informações efetivas.

Neste contexto, a hipótese apresentada neste trabalho é de que os dados de reflectância espectral da cultura de milho segunda safra, obtidos por sensores multiespectrais em nível aéreo (câmeras digitais acopladas a VANT) e hiperespectrais em nível de campo (espectrorradiômetro), possuem capacidade para caracterizar as diferentes condições nutricionais impostas a planta, permitindo distinção e identificação de tratamentos, e predição de teores de P foliar e produtividade.

2. OBJETIVO GERAL

O objetivo desta dissertação é caracterizar e avaliar aplicações de dados espectrais da cultura de milho segunda safra sob diferentes fontes e doses de adubo fosfatado, a partir da coleta destes dados com os sensores hiperespectral a nível de campo e multiespectral aéreo.

2.1 Objetivos específicos

- a) Analisar o comportamento espectral da cultura de milho segunda safra de acordo com níveis de nutrição por adubo fosfatado;
- b) Elaborar modelos discriminantes que permitam a classificação de indivíduos em condições nutricionais semelhantes na área experimental;
- c) Avaliar o desempenho dos índices de vegetação obtidos por dados espectrais coletados pelo espectrorradiômetro e câmeras digitais, na distinção de plantas sob diferentes níveis de nutrição por adubo fosfatado;
- d) Obter modelo matemático para predição de P foliar em plantas de milho utilizando as respostas espectrais da cultura, a partir do método PLSR (Partial Least Square Regression);
- e) Obter modelo matemático para predição de produtividade da cultura de milho segunda safra, utilizando as respostas espectrais das plantas, a partir do método PLSR.

3. REVISÃO DE LITERATURA

3.1 Aspectos gerais sobre a cultura do milho

3.1.1 Importância econômica

Atualmente, soja, milho, arroz e algodão são as principais culturas produzidas no Brasil, respectivamente. O milho plantado a partir de janeiro de cada ano, também chamado de milho segunda safra, representa 70,9 milhões de toneladas do grão dentre as 98,4 milhões de toneladas de milho totais considerando primeira, segunda e terceira safra produzidos no país, de acordo com o Relatório de Acompanhamento da Safra Brasileira (CONAB, 2019). O Brasil é um dos maiores produtores de milho do mundo (CASTRO et al., 2016).

Ainda de acordo com Conab (2019), os Estados de Mato Grosso, Mato Grosso do Sul, Goiás e Paraná são os principais produtores de milho segunda safra em âmbito nacional, com área plantada total de 12.878 mil hectares e produtividade média da cultura de 5.508 kg ha⁻¹.

O milho é um produto fundamental para a agricultura brasileira, cultivado em todas as regiões do País, em mais de dois milhões de estabelecimentos agropecuários. Nas últimas décadas, a cultura passou por grandes transformações, tendo como destaque sua redução na área de subsistência de pequenos produtores e o aumento do seu papel como agricultura comercial eficiente, com deslocamento geográfico e temporal da produção (CONTINI et al., 2019).

Além de sua utilização como alimento *in natura*, alguns produtos derivados de milho também são fabricados, como farinhas, pães, bolos, ração animal, entre outros e também é utilizado em ingredientes de bebidas, como a cerveja, por exemplo. Esse amplo mercado de produção e utilização dos grãos gera emprego e renda para a população.

No ano de 2019, a cultura apresentou crescimento no faturamento do país em 15% e está entre os produtos brasileiros com maiores altas nas exportações totais, com aumento de US\$ 2,9 bilhões, gerando US\$ 5 bilhões de receita e exportação de 28,9 milhões de toneladas de grãos (CNA, 2019). Este último cita também que, no geral, os cultivos agrícolas tiveram bom desenvolvimento na safra 2018/2019 diante da ausência de alterações drásticas nas condições meteorológicas.

Esses números são suportados pela importância nacional e internacional do milho, e a perspectiva de aumento na exportação servirá de incentivo para aumento na produção. Segundo Contini et al. (2019) a variável mais forte a impulsionar a produção de milho serão as exportações, projetadas para crescer 51,1%, que corresponde a um volume de 39 milhões de toneladas.

3.1.2 Características da planta

O milho (*Zea mays* L.), pertencente à família Poaceae, teve suas primeiras plantas encontradas na região do México. Devido a sua característica de adaptabilidade e a ampla variedade de genótipos, as áreas de cultivos estendem-se desde a latitude de 58° Norte até 40° Sul, sendo cultivados em climas tropicais, subtropicais e temperados (MONTEIRO, 2009). O interesse geral quanto a cultura é a alimentação *in natura*, produção de subprodutos para alimentação humana e animal, e exportação.

O milho é cultivado em regiões cuja precipitação varia de 300 a 5.000 mm anuais, sendo que a quantidade de água consumida por uma safra durante o seu ciclo está em torno de 600 mm (MAGALHÃES e DURÃES, 2006). Os autores ainda citam que o efeito da falta de água, associado à produção de grãos, é particularmente importante em três estádios de desenvolvimento da planta: na iniciação floral e desenvolvimento da inflorescência, quando o número potencial de grãos é determinado; e no período de fertilização, quando o potencial de produção é fixado.

A taxa de desenvolvimento da planta, para qualquer híbrido, está diretamente relacionada com a temperatura, contudo, os estresses ambientais, tais como deficiências de nutrientes ou de umidade, também podem alterar o tempo entre os estádios vegetativos, em geral, aumentando, enquanto para os estádios reprodutivos, esses fatores costumam diminuir o tempo (RITCHIE et al., 2003). A temperatura ideal de desenvolvimento situa-se entre 25 °C a 30 °C, já sob temperaturas abaixo de 10 °C, o crescimento é praticamente nulo, e temperaturas superiores a 40 °C também prejudicam o desenvolvimento da cultura, resultando em perda do rendimento de grãos (MONTEIRO, 2009).

A fim de monitorar o desenvolvimento da cultura, bem como padronizar períodos de aplicações de produtos fitossanitários ou aplicação de fertilizantes, o ciclo do milho foi subdividido em etapas denominadas estádios fenológicos. Existem dois sistemas normalmente utilizados para a divisão do ciclo da planta, estes são propostos por Ritchie e Hanway (1989) e FANCELLI (1986). Em ambos, a divisão entre os estádios é caracterizada por eventos fisiológicos que ocorrem em cada etapa. Neste trabalho, foi utilizado como referência os estádios fenológicos caracterizados por Ritchie e Hanway (1989), conforme apresentado na Tabela 1.

Fatores como temperatura, umidade, disponibilidade de nutrientes, época de plantio, radiação solar e híbrido podem influenciar no maior ou menor tempo dentre os estádios. Também, o número de grãos que se desenvolvem, o tamanho final dos grãos, a taxa de

incremento no peso dos grãos e a duração do período de crescimento reprodutivo variarão entre diferentes híbridos e condições ambientais (RITCHIE et al., 2003).

Tabela 1. Caracterização dos estádios fenológicos para a cultura de milho. (Adaptado de Ritchie e Hanway, 1989).

Estádios vegetativos	Características de identificação
VE	Germinação e emergência
V1	Primeira folha totalmente expandida ¹
V2	Segunda folha totalmente expandida
V3	Terceira folha totalmente expandida
V6	Sexta folha totalmente expandida
V12	Décima segunda folha totalmente expandida
Vn	Segue até o pendoamento
VT	Pendoamento
Estádios reprodutivos	Características de identificação
R1	Embonecamento e polinização
R2	Grão bolha d'água
R3	Grãos leitoso
R4	Grão pastoso
R5	Formação de dente
R6	Maturidade fisiológica

¹Folha totalmente expandida se diz quando é possível a visualização de sua aurícula

3.1.3 Importância do fósforo para cultura

O manejo adequado da adubação envolve uma série de fatores como, por exemplo, as necessidades da cultura, época de plantio, características do solo em que se trabalha, escolha do adubo adequado, definição do método de aplicação, aspectos gerenciais da propriedade e condições de mercado quanto ao aspecto custo/benefício e até mesmo técnicas de manejo conservacionista do solo.

Dentre as principais exigências nutricionais do milho se encontram o N, K, Ca, Mg e P. Dentre estes, o nutriente absorvido em maior quantidade é o N, seguido por K, P, Ca e Mg (COELHO e FRANÇA, 1995; SBCS/NEPAR, 2017; VASCONCELLOS et al., 1983). Embora o fósforo não seja um dos elementos exigidos em maior quantidade pela planta, as doses de adubação recomendadas geralmente são altas devido à baixa eficiência de aproveitamento do nutriente pela cultura, que é em torno de 20% a 30% do adubo aplicado (Coelho, 2006), devido a interação do nutriente com o solo.

Grande parte dos solos brasileiros apresentam deficiência de fósforo. Segundo Fernandes (2006) o teor de P lábil total nos solos brasileiros está entre 0,2 e 5,0 g kg⁻¹, mas apenas uma pequena fração está disponível para as plantas. Isso ocorre devido a interação do

nutriente com o solo, o qual é adsorvido por suas partículas coloidais devido as suas propriedades de superfície, ficando em grande parte indisponíveis. Assim, mesmo quando são aplicados fertilizantes, a maior parte do P adicionado é adsorvida em coloides de solo, tornando-se com o tempo, não disponível, sem propiciar uma esperada contribuição para a produção vegetal (FERNANDES, 2006).

O pH do solo também é um fator de influência na disponibilidade de P. Em valores baixos de pH há tendência de formação de fosfatos insolúveis de ferro e alumínio em solos, enquanto em valores altos, ocorre predominância de fosfatos insolúveis em cálcio, contudo, qualquer dos casos resulta em baixas concentrações de P (RAIJ, 2011).

O fósforo atua na fotossíntese e na respiração das plantas, como integrante de ácidos nucleicos, como DNA (Ácido Desoxirribonucleico) e RNA (Ácido Ribonucleico), fosfolipídeos, coenzimas NAD (Nicotinamida Adenina Dinucleótido) e NADP (Nicotinamida Adenina Dinucleótido Fosfato), ATP (Adenosina Trifosfato) e outros compostos importantes para o desenvolvimento vegetativo, assim, todos os processos na planta, que envolvem gasto de energia, desde a absorção de nutrientes até a formação dos diferentes órgãos, tem a participação direta ou indireta desse nutriente (BORGES, 2006). Em ambos DNA e RNA, o fosfato forma uma ponte entre unidades ribonucleosídeo para formar macromoléculas, enquanto como fosfolipídio, as funções estão relacionadas à sua estrutura molecular, onde existe uma região lipofílica e uma hidrofílica, e a carga elétrica da região hidrofílica influencia nas interações entre superfícies de biomembranas e íons no meio circundante, quanto aos ésteres de fosfato, estes têm função e formação diretamente relacionadas ao metabolismo energético das células e aos fosfatos ricos em energia (MARSCHNER, 2012).

Segundo Ritchie et al. (2003) a absorção de nutrientes começa antes mesmo da planta emergir e, quanto ao fósforo, a absorção continua até próximo ao período de maturidade para o milho. Os autores citam também que grande parte do fósforo e de alguns outros nutrientes é translocada da parte vegetativa da planta para o grão assim que inicia seu desenvolvimento, e neste momento, pode ser observada deficiência do nutriente na folha caso não haja suprimento necessário. Havendo deficiência, o P não metabolizado no vacúolo pode sair da célula, sendo direcionado para os órgãos mais novos da planta e, então os sintomas de deficiência aparecem, em primeiro lugar, nas partes mais velhas, que apresentam coloração verde-arroxeadas como consequência da acumulação de antocianina, crescimento reduzido (Fernando, 2006; Sfredo, 2008), manchas necróticas, caules delgados, morte das folhas mais velhas e maturação retardada (TAIZ e ZEIGER, 2013). O tamanho final das espigas, folhas, altura de planta,

quantidade e qualidade de grãos e outras partes da planta de milho dependem, em grande proporção, da disponibilidade de suprimento adequado de nutrientes.

Alguns estudos indicam as fases de maior e menor absorção dos nutrientes, denominada marcha de absorção. Bull e Cantarella (1993) trabalhando com cinco cultivares de milho, observaram maior absorção de P entre 80-100 dias após emergência. Ritchie et al. (2003) observaram absorção do nutriente mais intensa nos estádios vegetativos, porém, contínua durante todo o ciclo, com estabilização a partir do estágio R5.

Borges (2006) trabalhando com duas cultivares de milho, também observou comportamento linear da cultura no acúmulo de P, com valor máximo encontrado próximo a maturidade fisiológica. Os autores citam que o acúmulo de P no grão seguiu essa mesma tendência, e que a ordem de nutrientes com maior acúmulo no grão foi N>K>P>Mg>S>Ca>Mn>B>Zn>Cu.

A demanda por alimentos e fontes energéticas vem ocasionando, cada vez mais, o uso intensivo do solo e de fertilizantes com o intuito de aumento de produtividade. Contudo, cabe ressaltar a importância do conhecimento da cultura com a qual se trabalha, bem como as características de solo e fertilizante utilizado para que os esforços e investimentos tenham resultado efetivo.

3.2 Fertilizantes fosfatados

Para garantia de qualidade dos produtos e produção, a classificação, definições, registro de estabelecimento e de produtos, a autorização de comercialização e uso de materiais secundários, armazenamento, embalagem, rotulagem e demais parâmetros que participam da toda cadeia de produção de fertilizantes são regidas por Instruções Normativas do Ministério da Agricultura, Pecuária e Meio Ambiente, como a IN MAPA nº 53/2013 (alterada pela IN MAPA 6/2016) e 39/2018 juntamente com seus anexos.

A maior parte da matéria prima usada na fabricação de fertilizantes fosfatados é extraída de minas, cujo principal mineral é a fluorapatita, ainda assim, esta raramente serve como fertilizante sem antes passar por tratamentos que consistem em transformações químicas que destroem a estrutura da apatita, produzindo fertilizantes de maior eficiência agrônômica (FERNANDES, 2006; RAIJ, 2011).

O mineral pode ser tratado a partir de ácidos ou processo térmico, gerando diferentes fontes de adubo fosfatado, como superfosfatos, fosfatos de amônio, termofosfatos, fosfatos naturais e subdivisões dentro destes. A escolha de qual fonte usar depende dos subprodutos de

interesse, também gerados no processamento do fertilizante (nutrientes em menor proporção no fertilizante) e, principalmente, da velocidade de solubilização (portanto disponibilização do nutriente) desejada. No Brasil, as fontes de adubo fosfatado mais utilizadas são as solúveis em água e citrato neutro de amônio, principalmente quando se trata de culturas agrícolas, devido a seu ciclo rápido, contudo, características do solo também devem ser avaliadas para a escolha do fertilizante.

Segundo Bedin et al. (2003) as características de solubilidade das fontes de P são de grande importância em relação à sua eficiência: os fosfatos de maior solubilidade, sendo mais prontamente disponíveis, favoreceriam a absorção e o aproveitamento do nutriente, principalmente pelas culturas de ciclo curto.

Os autores concluem citando que, no entanto, essa rápida liberação do P pode também favorecer o processo de adsorção específica e precipitação das formas solúveis pelos componentes do solo, originando compostos fosfatados de baixa solubilidade e indisponibilizando o nutriente para as plantas, sendo tal fenômeno tanto mais expressivo quanto mais argiloso for o solo. Assim, é importante o conhecimento das características da planta, solo e fertilizante a ser utilizado, bem como a interação entre estes.

3.3 Sensoriamento remoto aplicado a agricultura

3.3.1 Conceito geral e princípio

O sistema de sensoriamento remoto pode ser definido como um conjunto de técnicas e sensores utilizados para detectar e armazenar as informações de intensidade da radiação eletromagnética emitida ou refletida por um objeto em um comprimento de onda característico e particular, também denominado de assinatura espectral.

A radiação eletromagnética pode ser subdividida em diferentes comprimentos de onda (bandas) os quais fazem parte do espectro eletromagnético e, para cada um desses comprimentos de onda, existe um comportamento espectral de absorção, transmissão e reflexão a partir dos diversos alvos de interesse (FONSECA e FERNANDES, 2004). Assim, considerando que diferentes alvos podem apresentar respostas espectrais características, estes podem ser diferenciados e identificados na natureza (SABINS Jr., 1987).

Técnicas de sensoriamento remoto aplicado a agricultura possuem papel fundamental na determinação de uso e ocupação do solo, planejamento territorial, monitoramento do meio ambiente (Fernandes, 2016) e inclusive no monitoramento de culturas agrícolas, que é o

objetivo principal deste trabalho, pois permitem coletas de informações ao longo do ciclo de vida da planta por meio de métodos não destrutivos (GRACIA-ROMERO et al., 2017).

Além disso, com o auxílio de técnicas estatísticas multivariadas, é possível realizar uma avaliação indireta de múltiplos parâmetros agronômicos de maneira rápida, eficiente e sem a necessidade de destruir as plantas na coleta de amostras (EL-HENDAWY et al., 2019).

Alguns trabalhos utilizando o comportamento espectral de reflectância aplicado a agricultura tem sido voltados para avaliação do comportamento espectral de culturas impostas a diferentes condições de déficit hídrico (Carvalho et al., 2015; Crusiol et al., 2017; El-Hendawy et al., 2019), níveis nutricionais fósforo (Gracia-Romero et al., 2017; Li et al., 2018), níveis nutricionais de potássio (Furlanetto, 2018), nitrogênio (Gasparotto, 2014; Muñoz-Huerta et al., 2013; Souza et al., 2009) identificação de injúrias devido a patógenos (Arantes et al., 2016; Martins e Galo, 2015) e até mesmo caracterização e mapeamento de solos (CEZAR et al., 2013; NANNI, 2000).

Quanto a culturas agrícolas, as diferenças de reflectância que permitem a discriminação de espécies de plantas ou tipos de vegetação podem ser atribuídas às características das folhas e dossel. As folhas de uma dada espécie tendem a ter uma superfície característica, espessura, estrutura interna e conteúdo de pigmento; da mesma forma, o dossel, tende a ter uma estrutura ou geometria característica. Todos esses fatores influenciam as propriedades ópticas das folhas e dossel, e os padrões de reflexão representam a integração de seus efeitos (KNIPLING, 1970).

A detecção de culturas doentes ou estressadas fisiologicamente é uma aplicação importante do sensoriamento remoto para o meio agrícola. Seu valor reside no fato de permitir que ações corretivas sejam tomadas e que as previsões de rendimento sejam ajustadas em tempo hábil.

3.3.2 Tipos de sensores e níveis de aquisição de dados

Quando se trabalha com técnicas de sensoriamento remoto para estudo de alvos de interesse, existe uma série de equipamentos capazes de capturar o fluxo de Radiação Eletromagnética (REM) e processar esta informação em dados passíveis de interpretação (STEINER et al., 2008).

Estes sensores podem ser classificados como passivos, quando não possuem luz própria e então necessitam de uma fonte de luz alternativa; ou ativos, quando possuem sua própria fonte de radiação eletromagnética. Além disso, também podem ser classificados como imageadores

para aqueles que coletam dados a partir de imagens; e não-imageadores para aqueles que coletam dados quantitativos, sem obtenção de imagens.

Como exemplo, temos as câmeras multiespectrais, que são sensores passivos e imageadores, enquanto o espectrorradiômetro Fieldspec é um sensor ativo (quando utilizado o Probe específico para emissão de luz do equipamento) e não-imageador.

Outra classificação que também é utilizada na caracterização de sensores é quanto a quantidade de bandas que o mesmo trabalha. Sensores multiespectrais registram a REM incidente em poucas bandas do espectro eletromagnético, normalmente RGB (Red Green Blue) e/ou NIR (Near Infrared), enquanto sensores hiperespectrais registram a REM incidente em um elevado número de bandas, podendo chegar a mais 1.000 no caso de espectrorradiômetros (MOREIRA, 2011).

Na Figura 1 observa-se a diferença de dados gerados por sensores multi e hiperespectrais. Em geral, dados hiperespectrais são mais detalhistas na caracterização dos alvos de interesse devido à grande quantidade de bandas que os representa.

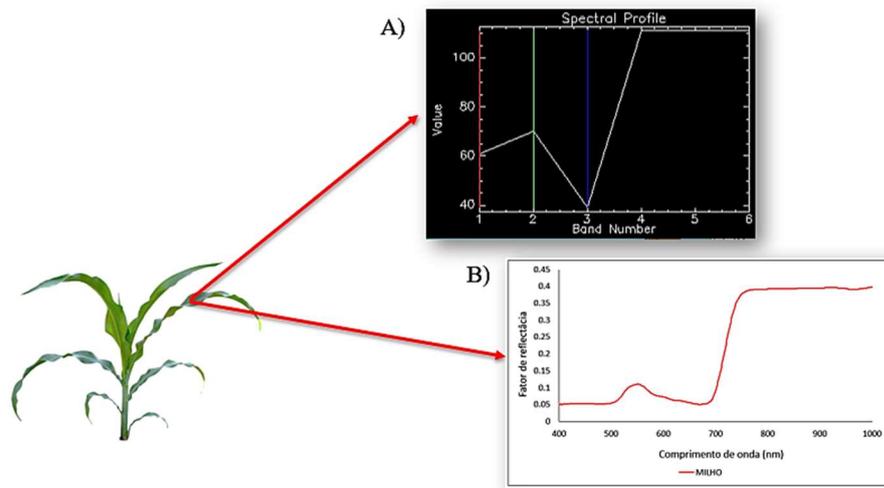


Figura 1. Representação de gráficos gerados a partir de dados espectrais coletados de plantas de milho. A) Dados multiespectrais com quatro bandas (R-G-B e NIR); B) Dados hiperespectrais com 600 bandas.

Outra característica de diferenciação entre sensores são as resoluções com as quais trabalham. De acordo com Jensen (2009), as resoluções são subdivididas em:

a) Resolução espacial: referente ao tamanho do pixel de um sensor imageador, em unidade de metro, importante porque quanto menor o pixel, melhor podem ser visualizados os detalhes da imagem e distinção de feições;

b) Resolução espectral: relacionada a quantidade e largura de bandas, onde quanto maior o intervalo, menor a resolução espectral;

c) Resolução temporal: refere-se ao tempo de revisita do sensor (intervalo de tempo entre coleta de dados);

d) Resolução radiométrica: definida pelo processador do equipamento, é a quantidade de níveis de cinza (também chamados de bits ou números digitais) com que a energia eletromagnética é quantizada. Assim, quanto maior a resolução radiométrica, maior fracionamento da REM (quantidade de níveis de cinza) e conseqüentemente maior possibilidade de caracterização espectral dos alvos de interesse.

Quanto aos níveis de aquisição de dados a partir de técnicas de sensoriamento remoto, estes podem ser divididos em: orbital (por meio de sensores a bordo de satélites), suborbital/aéreo (acoplado o sensor em plataformas aéreas, como aeronaves ou VANT, por exemplo) e terrestre (utilizando sensores a nível de campo, como o Fieldspec, por exemplo, ou então em laboratório).

Diferentes sensores têm sido utilizados na coleta de dados de reflectância espectral, sendo os principais os próprios satélites (Canavesi et al., 2010; Martins e Galo, 2015); câmeras acopladas em VANT ou aeronaves (Bogrekci et al., 2005; Furlanetto 2018; Pullanagari et al., 2016; Yanli et al., 2015) e espectrorradiômetros (LI et al., 2018; LI, L et al., 2018; LOOZEN et al., 2019; PIMSTEIN et al., 2011; ZHAI et al., 2013).

Esses sensores captam a interação entre a REM e o objeto de interesse, quantificando os valores de absorvância, transmitância e reflectância (MOREIRA, 2011). Na absorvância, a energia é absorvida e convertida em outras formas de energia, enquanto a transmitância é a fração de luz que atravessa a amostra, e a radiância refletida é a intensidade da REM refletida pela superfície do objeto, medida em diferentes comprimentos de onda, sendo esta a medida mais utilizada para caracterização de parâmetros de interesse. Outra medida de REM é a radiância emitida pelo objeto, nesta, o sensor detecta a radiação emitida por objetos após terem absorvido radiação solar.

A calibração radiométrica do sensor utilizado é essencial para obtenção de dados fidedignos e comparáveis. Para tanto, são utilizadas placas pintadas com sulfato de bário, teflon, ou então a placa Spectralon®, sendo esta última conhecida e utilizada por grande parte dos pesquisadores. Essa placa é utilizada como uma referência de máxima reflectância para calibração do sensor, assim, a reflectância dos demais alvos são mensuradas com base nesse

padrão, possibilitando a interpretação e comparação de dados obtidos em diferentes datas e locais.

A utilização de técnicas de sensoriamento remoto tem demonstrado operacionalização e resultados promissores. Contudo, é necessário conhecimento do equipamento a ser utilizado, técnicas para calibração do sensor e coleta de dados, bem como do processamento das informações obtidas para que sejam realmente representativas e comparáveis.

3.3.3 Comportamento espectral da vegetação

O desenvolvimento de sensores capazes de medir a reflectância espectral gerou oportunidade para descrever quantitativamente alguns parâmetros agrônômicos observados em culturas agrícolas. A principal motivação dos estudos em vegetação envolvendo a aplicação das técnicas de sensoriamento remoto, é baseado na compreensão da “aparência” que uma dada cobertura vegetal assume em um determinado produto obtido pela técnica, a qual é fruto de um processo complexo que envolve muitos parâmetros e fatores ambientais (PONZONI, 2002).

O princípio da técnica é baseado no fato de que a REM interage com as estruturas e demais componentes foliares, sendo absorvida ou refletida em diferentes proporções. Essa reflectância característica é captada por sensores e então se torna passível de interpretação. Segundo Ponzoni (2002), quando a REM incide sobre a planta, uma pequena quantidade de luz é refletida das células da camada superficial, enquanto a maior parte é transmitida para o mesófilo esponjoso, onde os raios incidem nas paredes celulares, sendo refletidos de acordo com o ângulo da parede, assim, dado o grande número de paredes celulares dentro da folha, alguns raios são refletidos de volta, enquanto outros são transmitidos através da folha.

Dentre as propriedades que influenciam na radiação solar refletida pela folha ou copa da vegetação e, portanto, na sua “aparência” ou assinatura espectral, podem ser citados o estágio de desenvolvimento da planta, estrutura da folha, maturidade da folha, pigmentos, orientação estrutural do mesófilo, folhas danificadas, folhas no sol ou na sombra, folhas pilosas, conteúdo de água na folha, espaços porosos de ar na folha (Liu, 2007), condições fisiológicas, arquitetura do dossel e até mesmo nutrientes presente na folha.

Segundo Fernandes (2016) existem variações marcantes na estrutura de diferentes espécies ou até mesmo de espécies iguais, mas cujas plantas se desenvolveram em condições ambientais diferentes. No caso deste trabalho, as diferenças se dão a partir de níveis de nutrição impostos a planta.

De acordo com Jensen (2009) e Knipling (1970), quando as técnicas de sensoriamento remoto são aplicadas ao estudo agrícola, o intervalo de comprimento de ondas que melhor explica a vegetação é estabelecido entre 350 nm a 2.500 nm, pois este intervalo está associado as interações da REM com as estruturas celulares vegetais.

A curva espectral característica de vegetação possui baixa reflectância na região visível do espectro eletromagnético e alta reflectância na região do infravermelho próximo. Na região do visível, a reflectância e a transmitância podem chegar a menos de 15%, e a reflectância apresenta um pico no comprimento de onda próximo de 530 nm, referente à região verde do espectro (Moreira, 2011), enquanto na região do infravermelho próximo, a absorção é muito baixa (menos de 15%) e a reflectância pode chegar até 50% (TUCKER e GARRATT, 1977).

Na região do visível, os pigmentos são responsáveis pela baixa reflectância, pois absorvem eficientemente a REM; a energia é absorvida seletivamente pela clorofila e é convertida em calor ou fluorescência, e também convertida fotoquimicamente em energia estocada na forma de componentes orgânicos por meio da fotossíntese (GATES et al., 1965; PONZONI, 2002). Na região do violeta ao ciano, as clorofilas e carotenoides são responsáveis pela absorção da REM, enquanto na região do verde a absorção se deve ao teor de clorofila e espessura da folha, e na região do vermelho apenas as clorofilas influenciam na absorção (FALCIONI et al., 2017).

A absorção no azul e vermelho é sempre alta, mesmo em folhas com baixo conteúdo de pigmentos, e relacionada a primeira camada do parênquima paliçádico, enquanto isso, a região do verde tem a absorção dependente da quantidade de clorofila, e a REM é absorvida mais eficientemente por folhas mais espessas devido as estruturas adicionais de captação de luz, visto que a absorção da luz verde pelas clorofilas é pouco eficiente (FALCIONI et al., 2017; MORIWAKI et al., 2019).

Já na região do infravermelho próximo existe pequena absorção da REM e considerável espalhamento interno na folha, que ocorre de forma semelhante ao longo de toda esta banda. Esta característica se deve a estrutura do mesófilo (forma e tamanho da célula, bem como quantidade de espaço intercelular) e alterações de espessura (GATES et al., 1965; HATFIELD et al., 2008). De maneira geral, quanto mais lacunosa for a estrutura interna foliar, maior será o espalhamento interno da radiação incidente e, conseqüentemente, maior será a reflectância (PONZONI, 2002).

Na região do infravermelho médio, a absorção, devido à água líquida, predomina na reflectância espectral das folhas; já quanto aos comprimentos de onda relativos ao ultravioleta,

estes não são considerados porque grande quantidade dessa energia é absorvida pela atmosfera e a vegetação não faz uso dela (Moreira 2011; Ponzoni 2002), assim, muitos autores optam pela utilização da porção visível e infravermelho próximo na avaliação de culturas. A Figura 2 apresenta o comportamento espectral da vegetação na região do visível, infravermelho próximo ou Near Infrared (NIR) e infravermelho médio com suas características de absorção e reflexão da REM, e os componentes que influenciam.

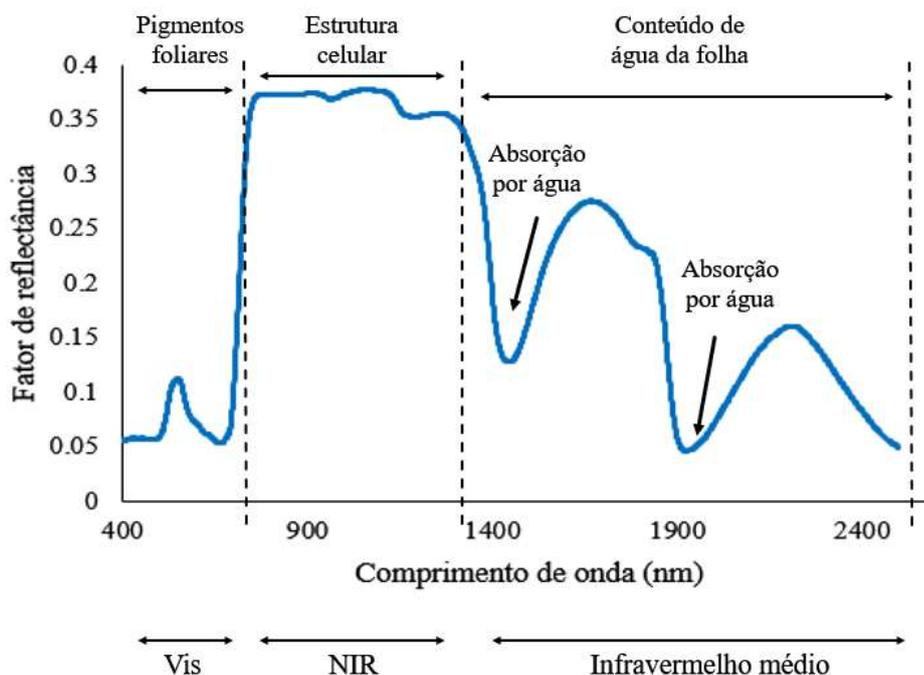


Figura 2. Comportamento espectral característico de vegetação sadia. Adaptado de Novo (1989).

No mecanismo de reflexão da folha, apenas uma parte da energia incidente é refletida, o restante é absorvido ou transmitido. Esses três componentes estão intimamente relacionados, e é necessário considerar os três para avaliar as bases físicas e fisiológicas da refletância das folhas (KNIPLING, 1970). Considerando toda REM incidente na vegetação, cerca de 50% são absorvidos pela planta e utilizados em processos fisiológicos, enquanto para os 50% restante, podem ocorrer processos de transmissão e reflexão (MOREIRA, 2011). A espessura da folha também é fator importante no caminho da REM, já que geralmente a transmitância é maior do que a refletância para folhas finas, mas o inverso acontece com folhas grossas (PONZONI, 2002).

Quando as plantas sofrem algum tipo de estresse, ocorre uma série de alterações fisiológicas e bioquímicas como resposta a situação, que resultam em alterações nas suas

respostas espectrais, sendo passíveis de mensurações por meio de técnicas do sensoriamento remoto.

3.3.4 Índices de vegetação (IV's)

Uma grande variedade de índices de vegetação tem sido propostos pela literatura com o objetivo de estudar as respostas espectrais da vegetação a partir de combinações de bandas do espectro eletromagnético. Estes IV's têm sua base na reflexão foliar, e a compreensão de como esses índices de refletância se relacionam com características de folhas e dossel de culturas pode ser a base para o refinamento da técnica e aplicação para monitoramento e identificação de problemas agrônômicos (HATFIELD et al., 2008).

Os índices de vegetação espectral são equações matemáticas que buscam correlacionar bandas espectrais a fim de realçar características da vegetação. A literatura tem dado preferência as bandas do visível e infravermelho próximo na elaboração desses índices, pois essas faixas de comprimento de onda respondem a aproximadamente 90% da variação espectral da vegetação (PONZONI e SHIMABUKURO, 2007; ROSA, 2007).

Os IV's podem ser utilizados para monitorar, analisar e mapear variações temporais e espaciais na estrutura da vegetação, bem como determinados parâmetros biofísicos (GITELSON et al., 2002). Também auxiliam na normalização de efeitos de iluminação e condições atmosféricas, variações no substrato, topografia, solo e vegetação senescente, possibilitando sua utilização em diferentes condições vegetais, permitindo avaliações espaciais e temporais (JENSEN, 2009). De acordo com Pinter Jr et al. (2003) os índices de vegetação servem de base para muitas aplicações de sensoriamento remoto no manejo das culturas, porque estão bem correlacionados com a biomassa verde e o índice de área foliar dos dosséis das culturas.

Como exemplos de índices de vegetação, podem ser citados SAVI (Índice de Vegetação Ajustador do Solo) elaborado por Huete (1988), GRVI (razão entre infravermelho próximo e verde) proposto por Sripada et al. (2006), RVI (razão entre infravermelho próximo e vermelho) elaborado a partir do trabalho de Birth e Mcvey, (1968), GNDVI (índice de vegetação da diferença de verde normalizado) proposto por Gitelson et al. (1996) e NDVI (índice de vegetação por diferença normalizada) elaborado por Rouse et al. (1974), sendo este último um dos mais utilizados na literatura.

Na Figura 3 estão apresentados alguns exemplos de IV's, lembrando que uma imagem obtida pela equação de índices de vegetação é composta por diferentes níveis de cinza, e que pode ser colorida por composição falsa cor para auxiliar na identificação visual da vegetação.

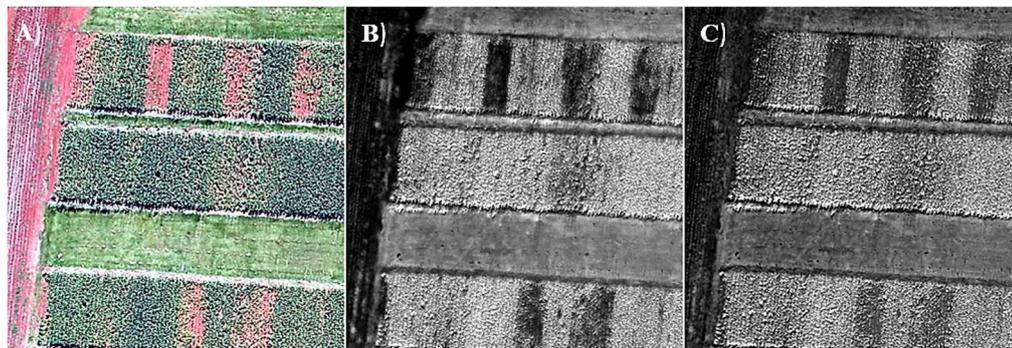


Figura 3. Índices de vegetação aplicados a imagens. A) Original; B) NDVI; C) GNDVI.

Diversos autores tem utilizado esta técnica para determinação de diferentes parâmetros em culturas, como por exemplo, identificação de déficit hídrico (Carvalho et al., 2015; Crusiol et al., 2017; El-Hendawy et al., 2019), estimativa de parâmetros biofísicos, como índice de área foliar, biomassa e produtividade (Groff et al., 2013; Osborne et al., 2002; Sakamoto et al., 2012; Xavier et al., 2006; Zhang et al., 2019), e estimativa de quantidade de nutrientes na folha (CHANDEL et al., 2019; LOOZEN et al., 2019; MAHAJAN et al., 2014; PIMSTEIN et al., 2011; SOUZA et al., 2009). A diferença entre esses índices de vegetação são as bandas que utilizam, cabendo ao pesquisador selecionar o mais adequado para o seu objetivo.

3.4 Utilização de VANT no monitoramento agrícola

Veículo Aéreo Não Tripulado (VANT) são aeronaves pequenas, cujo controle não necessita de contato direto e são capazes de realizar atividades como monitorar e mapear pontos de interesse (MEDEIROS, 2007). Segundo Passos et al. (2014) as aeronaves não pilotadas são subdivididas em veículos aéreos não tripulados (VANT) e veículos aéreos remotamente controlados (VAR), mas todos eles, por não serem tripulados, são denominados genericamente de VANT.

Segundo Jorge e Inamasu (2014) o termo “Veículo Aéreo Não Tripulado” é mundialmente reconhecido e inclui uma grande gama de aeronaves que são autônomas, semiautônomas ou remotamente operadas. Os autores também citam que o interesse nesses equipamentos tem crescido ao redor do mundo e que os avanços recentes na tecnologia computacional, desenvolvimento de software, materiais mais leves, sistemas globais de

navegação, avançados links de dados, sofisticados sensores e a miniaturização são os motivos do aumento de desenvolvimentos de VANTs.

Diversos autores tem utilizado este sistema para auxiliar na coleta de dados. Dentre as aplicações, podem ser citados monitoramento de lavoura agrícola, análise de processos erosivos do solo, monitoramento de plantas daninhas, análise de cobertura de pastagem, mapeamento de áreas de interesse, uso e ocupação do solo, dentre outros objetivos (CANDIAGO et al., 2015; CATANI, 2018; PEREIRA, 2017; SANTOS, 2019).

Na área agrícola, a utilização VANTs está ganhando cada vez mais espaço no monitoramento de lavouras. Este equipamento é utilizado como plataforma de fácil operação para fixação de sensores utilizados na avaliação e coleta de dados de culturas por via aérea. Sua aplicação na área agrícola e em missões de reconhecimento vem sendo favorecida e facilitada pelo atual estágio de desenvolvimento tecnológico, principalmente pela redução do custo e do tamanho dos equipamentos, e pela necessidade de otimização da produção (JORGE e INAMASU, 2014).

Segundo Fernandes (2016) a alta capacidade de revisita na lavoura, aliado a facilidade para obtenção de imagens com alta resolução espacial, espectral e radiométrica, também são benefícios da utilização de sensores acoplados a VANTs. O autor ainda cita que dentre as aplicações de VANTs no agronegócio, podem ser citados o manejo de culturas agrícolas, verificação de estresse hídrico, estimativa de falhas no plantio e mapeamento de áreas para aplicação de defensivos ou adubação.

O uso de VANT em agricultura de precisão tem focado na utilização de sensores baseados na espectroscopia de reflectância, ou seja, em medidas da reflexão da radiação eletromagnética após interação com diferentes superfícies em diferentes comprimentos de onda, preferencialmente abrangendo a região do visível, infravermelho próximo e infravermelho de ondas curtas (JORGE e INAMASU, 2014).

Aplicado ao monitoramento agrícola, pesquisadores tem utilizado principalmente sensores como câmeras digitais com objetivo de coletar dados espectrais de culturas e utilizá-los para distinção dos diferentes manejos aos quais estão submetidas, como diferentes condições hídricas e condições de adubação, por exemplo (Carvalho et al., 2015; Crusiol, 2017; El-Hendawy et al., 2019; Furlanetto, 2018), bem como associar esses dados aos diferentes manejos, a fim de poder classificar novos indivíduos nas mesmas condições (LI, L. et al., 2018; MAHAJAN et al., 2017; PULLANAGARI et al., 2016; SHAIIBU et al., 2015).

Isso é possível devido ao fato de que a vegetação possui uma curva de reflectância padrão, e alterações fisiológicas devido a diferentes manejos, condições de fertilidade e até mesmo disponibilidade de água, resultam em alterações nas curvas espectrais passíveis de serem identificadas e caracterizadas.

Para padronização e fidelidade dos dados obtidos pelos sensores, é necessário a calibração dos mesmos e processamento das imagens, realizado a partir de modelos de calibração gerados especificamente para cada sensor. Assim, cada câmera tem seu próprio modelo, devendo ser evitado o uso de modelos iguais em câmeras diferentes (WITHAGEN et al., 2007).

As tecnologias empregadas em VANTs e nos sensores acoplados a estes estão evoluindo rapidamente e com promessa de resultados promissores na agilidade e qualidade de dados obtidos a partir do dossel de culturas agrícolas, contudo, é de extrema importância a obtenção de conhecimentos de como trabalhar esses dados e calibração do sensor para aquisição de dados fidedignos e efetivos.

3.5 Estatística multivariada aplicada ao estudo de parâmetros agrônômicos

O método estatístico de análise multivariada é utilizado quando se trabalha com grande quantidade de variáveis ao mesmo tempo, as quais podem ou não ser interrelacionadas, diferente da análise univariada, que analisa a variável de forma isolada. Ao trabalhar com sensores hiperespectrais aplicando técnicas de sensoriamento remoto, a quantidade de variáveis (valores de reflectância) obtidas é muito grande, assim, ao utilizar técnicas univariadas, seria necessário obtenção de média de dados, e neste caso, pode se perder informações importantes.

Neste trabalho, foram utilizados os métodos multivariados de modelo linear discriminante e modelo de regressão pelo método dos mínimos quadrados parciais (PLSR). No modelo discriminante linear, são extraídas as informações das variáveis que melhor caracterizam os tratamentos estudados, em seguida, estes valores discriminados são utilizados para geração de modelos discriminantes (funções matemáticas) que permitem a classificação de novos indivíduos aos tratamentos então estudados. Essa classificação só terá resultado efetivo desde que os novos indivíduos a serem classificados tenham passado por tratamentos e condições semelhantes aos indivíduos utilizados para geração do modelo.

A análise discriminante tem por objetivo identificar as variáveis que distinguem determinados grupos, de modo que conhecendo suas características, seja possível prever a qual grupo pertencem (PESTANA e GAGEIRO, 2005). Khattree e Naik (2000) citam que esta é

uma técnica da estatística multivariada que estuda a separação de objetos pertencentes a uma população em duas ou mais classes. Segundo Karimi et al. (2005), o procedimento gera funções discriminantes para cada tratamento estudado em questão, por meio de combinações lineares das variáveis preditoras. Em seguida, categoriza os alvos nas classes, utilizando uma medida do quadrado das distâncias generalizadas (SIBANDA et al., 2015). O método de aplicação pode ser visualizado no Tópico 4.8.1 deste trabalho.

Vários trabalhos tem utilizado este método multivariado para modelagem descritiva e preditiva referente a níveis de adubação com nitrogênio, potássio e fósforo em culturas agrícolas, diferenciação de genótipos de plantas, classificação de espécies arbóreas, identificação de patógenos, diferentes regimes hídricos aplicados a culturas, diferenciação de cultivares de soja, dentre outros (CRUSIOL, 2017; FIORIO et al., 2017; FURLANETTO, 2018; HADLICH, 2017; JIM, 2018; NOGUEIRA et al., 2008; PITHAN, 2019; SIBANDA et al., 2015).

Quanto aos modelos de regressões pelo método dos mínimos quadrados parciais, este modela as matrizes X e Y (reflectância e produtividade, por exemplo) simultaneamente para encontrar as variáveis latentes (também denominados Componentes Principais – PCs) em X que melhor preverão as variáveis latentes em Y . Este método de regressão fornece um modelo com uma equação expressa pelos coeficientes de regressão, a partir dos quais os valores Y previstos são calculados.

As vantagens do método incluem a capacidade de modelar múltiplas variáveis dependentes e independentes, capacidade de lidar com multicolinearidade entre as variáveis independentes, robustez mesmo diante de ruído nos dados e da falta de dados, além de criar variáveis latentes independentes com base no cruzamento dos dados que envolvam as variáveis de resposta, gerando previsões mais fortes (GARSON, 2016).

Segundo Almeida (2009), a regressão PLSR busca encontrar um conjunto de vetores base (variáveis latentes) para as variáveis independentes (neste trabalho, dados espectrais) e um conjunto separado de vetores base para as variáveis dependentes (produtividade, concentração dos nutrientes, por exemplo) e, em seguida, relacioná-los. A decisão sobre o número de fatores latentes a ser utilizado no modelo de calibração é essencial, pois os valores preditos pelo modelo são influenciados por estes. O número ideal de fatores latentes do PLSR é determinado quando observado o mínimo erro quadrático médio da raiz (RMSE – Root Mean Square error) (ZHAI et al., 2013).

A construção de modelos de regressão consistem em selecionar as amostras X e Y, aplicar a técnica PLSR (a calibração ajusta o modelo aos dados disponíveis, enquanto a validação verifica se há novos dados no modelo), verificar ocorrência de outliers, escolha do número de PCs a serem interpretados, diagnosticar e interpretar o modelo, e por fim, gerar valores de predição com amostras externas (não utilizadas no modelo). Mais detalhes do método de aplicação podem ser visualizados no Tópico 4.8.2 deste trabalho.

No setor agrícola, esta técnica aplicada a dados de reflectância das porções do visível e infravermelho próximo do espectro eletromagnético, tem sido muito utilizada por pesquisadores na estimativa de concentração de nutrientes foliares, como N, P e K (Li, L. et al., 2018; Li et al., 2018; Loozen et al., 2019; Mahajan et al., 2014; Ramoelo et al., 2013), concentração de biomassa (Li, Y. et al., 2017), quantidade de fibras (Wittkop et al., 2012), produtividade de culturas (Barmeier et al., 2017; Shaibu et al., 2015; Sharabian et al., 2014; Zhang e He, 2013), e até mesmo trabalhos referente a espectrorradiometria de solos (CEZAR et al., 2013; NANNI et al., 2004).

Pullanagari et al. (2016), trabalhando com dados hiperespectrais na investigação da variabilidade de concentrações de nutrientes em pastagem, citam que o modelo linear multivariado PLSR provou ser eficiente quando se trabalha com grande quantidade de dados, variáveis ruidosas e multicolineares, como os dados hiperespectrais obtidos por técnicas de sensoriamento remoto.

Os autores citam também que a PLSR modela o relacionamento entre um conjunto de variáveis independentes e dependentes, decompondo esses dados em variáveis latentes, que maximiza a covariância. Li, Y. et al. (2017) trabalharam com estimativa de biomassa em trigo a partir de dados espectrais, e citam que o método PLSR provou ser um algoritmo de regressão eficaz para estimativa de parâmetros fisiológicos da vegetação.

A predição de parâmetros agrônômicos por meio da aplicação de métodos multivariados utilizando dados espectrais tem demonstrado resultados promissores. Ainda sim, são necessários mais estudos e repetições para obtenção de padrões quanto a períodos e métodos de coleta de dados para auxiliar no refinamento e aplicabilidade da técnica, que trará grandes benefícios ao setor agrícola, com análises rápidas e práticas.

4. MATERIAL E MÉTODOS

Este trabalho foi desenvolvido em etapas distintas, cujo procedimento metodológico e materiais utilizados estão representados no fluxograma abaixo (Figura 4).

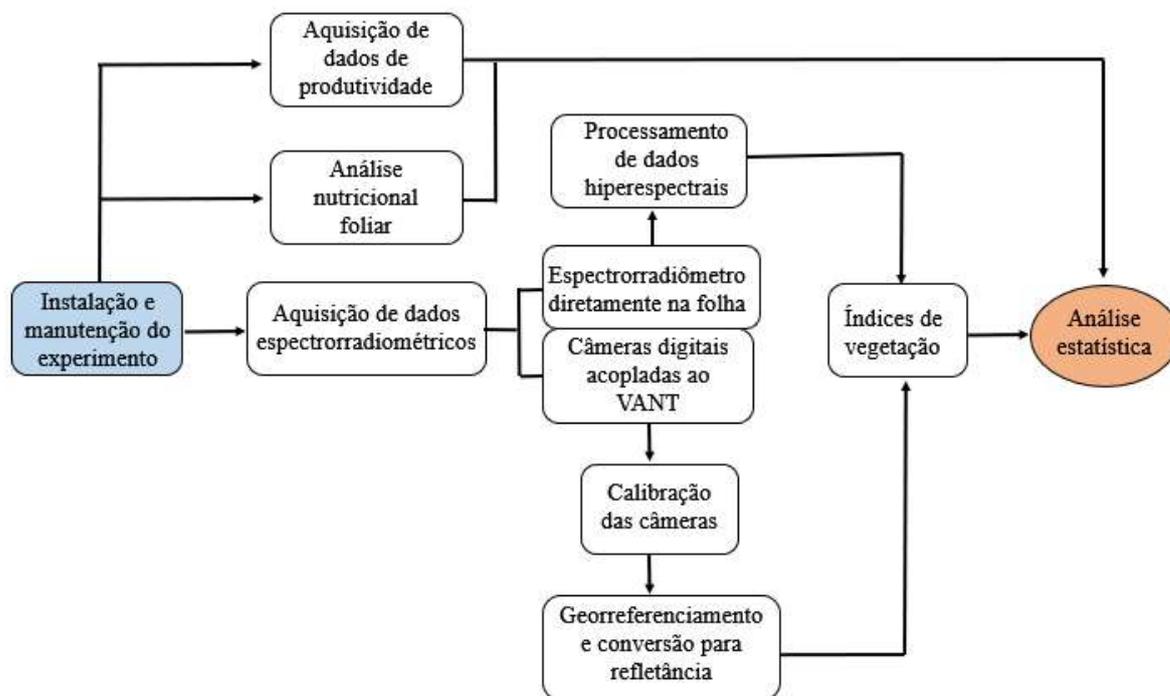


Figura 4. Fluxograma da metodologia e materiais utilizados no trabalho.

4.1 Descrição geral da área de estudo

4.1.1 Caracterização do município e da área experimental

A área de estudo localiza-se na Fazenda Experimental da Coamo – Cooperativa Agroindustrial, situada na cidade de Campo Mourão – PR, coordenadas geográficas 24°05' 46.79" S e 52° 21' 22.89" O. O solo da área experimental é classificado como LATOSSOLO VERMELHO Distroférico típico de textura muito argilosa, segundo o Sistema Brasileiro de Classificação de Solos (Santos et al., 2018), com teor de argila de 760 g kg⁻¹.

O clima da região de Campo Mourão é classificado como Cfa (subtropical com verão quente) segundo a classificação de Köppen, com precipitação média anual de 1.601 mm, UR média de 78%, temperatura mínima média anual de 20,1°C e máxima de 30,8 °C (dados obtidos pela estação meteorológica da COAMO). A classe de solo predominante na região é LATOSSOLO VERMELHO Distroférico de textura argilosa. Os solos da região são caracterizados como sendo férteis e de grande aptidão agrícola, e as culturas predominantemente implantadas são soja e milho.

A Fazenda Experimental possui estação meteorológica própria para monitoramento climático. Os dados referentes à temperatura e precipitação durante o período do experimento estão apresentados na Figura 5.

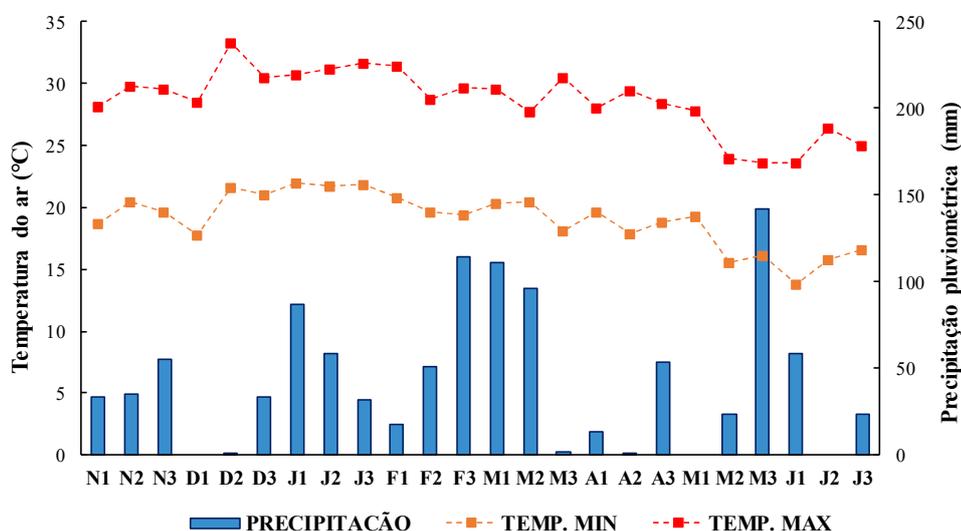


Figura 5. Dados de temperatura média (°C) e precipitação (mm) dos decênios mensais de novembro de 2018 a junho de 2019.

4.2 Implantação do experimento

Foram realizados dois experimentos consistidos por diferentes fontes de fertilizante fosfatado (Monoamônio Fosfato e Superfosfato Simples), os quais compartilharam a área experimental em mesmo delineamento e foram conduzidos simultaneamente, porém, em parcelas separadas e sem interação entre si, considerados então como experimentos distintos, com exceção do tratamento testemunha, que foi o único compartilhado pelos dois experimentos.

O delineamento experimental foi de blocos casualizados (DBC), constituído por cinco tratamentos, compostos por diferentes doses de adubo fosfatado (Tabela 2) e quatro repetições. Os tratamentos foram aplicados no sulco de semeadura e utilizado o sistema de semeadura direta.

Tabela 2. Fontes e doses de fósforo aplicadas nos tratamentos.

Tratamento	Proporção de P ₂ O ₅	Adubo MAP ¹	Adubo SS ²
	kg ha ⁻¹	kg ha ⁻¹	
T1	0	0	0
T2	30	62,5	167
T3	60	125	333
T4	120	250	667
T5	240	500	1.333

¹ MAP: Monoamônio Fosfato (48% P₂O₅), ² SS: Superfosfato Simples (18% P₂O₅).

As características das fontes de fertilizante fosfatado utilizadas foram:

Experimento 1: MAP (Monoamônio Fosfato), composto por aproximadamente 48% de P₂O₅, 9% de N e solubilidade em água 44%;

Experimento 2: SS (Superfosfato Simples), composto por aproximadamente 18% de P₂O₅, 16% de Ca, 10% de S e solubilidade em água 16% (Anexo I IN MAPA n°39, 2018).

A fim de homogeneizar a área experimental, anteriormente a implantação dos experimentos, foi realizada amostragem (0-20 cm de profundidade, 3 amostras por parcela) e análise de solo individual para as parcelas que comportariam cada tratamento e suas respectivas repetições (Tabela 3). A partir das análises, foi realizada aplicação, de forma manual, de corretivo para elevar o pH do solo e adubação de base (com exceção do fósforo) de acordo com as necessidades da cultura (SBCS/NEPAR, 2017).

Tabela 3. Características químicas do solo antes da instalação do experimento.

Tratamento	pH		P-Rem ¹	P ²	K ⁺	Ca ²⁺	Mg ²⁺	H ⁺ +Al ³⁺	Al ³⁺	V ³	CTC
	CaCl ₂	H ₂ O	mg L ⁻¹	mg dm ⁻³	----- cmolc dm ⁻³ -----			----- %			
1	4,1	4,6	6,06	4,1	0,11	0,81	0,34	9,35	1,95	11,9	10,6
2a	4,0	4,5	6,46	3,0	0,11	0,64	0,31	9,70	2,10	9,9	10,8
3a	4,5	5,0	7,89	2,5	0,21	1,55	0,95	6,94	0,45	28,1	9,7
4a	4,3	4,8	7,72	4,3	0,13	0,85	0,65	8,36	0,90	16,3	10,0
5a	4,9	5,5	8,18	4,8	0,20	1,43	1,01	6,44	0,10	29,1	9,1
2b	4,3	4,8	9,09	3,3	0,15	1,24	0,74	8,68	0,80	19,7	10,8
3b	4,5	5,0	9,49	2,9	0,15	1,92	1,12	7,76	0,40	29,1	11,0
4b	4,5	5,0	9,55	2,9	0,14	1,72	1,02	7,70	0,40	27,2	10,6
5b	4,3	4,8	8,69	3,0	0,17	1,20	0,67	8,36	0,95	19,6	10,4

a: Parcelas destinadas a aplicação de MAP; b: Parcelas destinadas a aplicação de SS; Fósforo remanescente¹; Fósforo²; Saturação de bases³. P e K extraídos com Melich-1; Ca, Mg e Al extraídos com KCl 1N.

A princípio a cultura implantada foi soja, contudo, a safra foi perdida devido à falta de precipitação nas semanas após seu plantio (início do mês de dezembro de 2018), resultando em graves falhas na emergência de plântulas nas parcelas. Considerando o ocorrido, as plântulas foram dessecadas logo após a emergência e plantado milho na área experimental, utilizando dos tratamentos já aplicados que até então não haviam sido utilizados.

A cultivar avaliada foi *Zea mays*, híbrido 30A37 PW MorganTM, com características de ampla adaptação para cultivo de verão ou safrinha entre regiões, ciclo precoce, estável e produtivo. A semeadura foi realizada no dia 29/01/2019, utilizando 3,6 sementes por metro e espaçamento de 60 cm entre linhas de plantio. A emergência ocorreu após seis dias. Foram realizados tratamentos fitossanitários com os produtos Engeo Pleno no dia 11/02/2019, Engeo

Pleno + Nomolt em 20/02/2019 e Primóleo + Soberan + Engeo Pleno em 28/02/2019. A adubação de base foi ajustada conforme SBCS/NEPAR (2017).

As parcelas experimentais consistiam de dimensões de 12 x 4,2 metros, com área total de 50,4 m², comportando 7 linhas de plantio. Foram consideradas como área útil três linhas centrais das parcelas.

4.3 Coleta de dados espectrorradiométricos

Para obtenção de dados espectrorradiométricos foram utilizados dois sensores remotos: espectrorradiômetro, para coleta de dados em nível terrestre, e câmeras fotográficas multiespectrais acopladas ao VANT (Veículo Aéreo Não Tripulado), para obtenção de imagens aéreas.

4.3.1 Coleta de dados com espectrorradiômetro

Foram obtidos dados espectrorradiométricos por meio do espectrorradiômetro ASD Fieldspec 3 Jr, fabricado pela ASD Inc., com resolução espectral de 3 nm na faixa entre 350 a 1.400 nm e 30 nm na faixa de 1.400 a 2.500 nm (Figura 6), com o auxílio do acessório ASD Plant Probe, conectado ao Fieldspec por um cabo de fibra óptica, para leituras radiométricas diretamente na folha. As configurações do software e aplicativo, coleta de dados e armazenamento de dados, é realizada por um computador ligado ao aparelho por um cabo de rede.

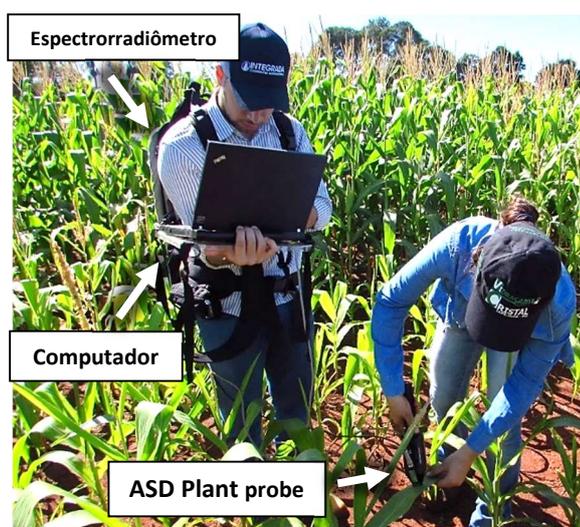


Figura 6. Esquema de trabalho a campo com o espectrorradiômetro.

O acessório ASD Plant Probe prende uma porção da folha em esquema de “pinça”, com auxílio do acessório *leaf clip*, isolando essa amostra de luminosidade externa e iluminando-a com sua fonte de luz própria, padronizando a iluminação para leitura de dados (Figura 7).



Figura 7. Exemplo de utilização do ASD Plant probe.

O sensor hiperespectral Fieldspec, capta valores espectrais nas porções Vis/NIR (Visível/Infravermelho próximo) do espectro eletromagnético por meio de um detector CCD e na porção SWIR (Infravermelho de ondas curtas) por meio do detector *Indium Gallium Arsenide* (InGaAs).

Além da iluminação padrão, é preciso realizar a otimização e calibração do sensor (*White Reference*) com uma placa de reflectância padrão, para isso é utilizada a placa Spectralon (Labsphere®), considerada como placa de reflectância máxima, a qual se encontra fixada em um dos lados da “pinça” do ASD Plant probe. Em seguida foram iniciadas as leituras espectrorradiométricas das folhas, posicionando o lado adaxial da folha de frente para o sensor de leitura, sobre um fundo negro e opaco, também integrante do acessório. Foram padronizadas as avaliações na última folha expandida de cada planta, realizando as leituras em 5 plantas por parcela, em busca de representatividade da parcela. O Fieldspec foi configurado para realizar 20 leituras (medidas) em cada amostragem por planta, obtendo como resultado a média dessas 20 leituras, assim, foram realizadas 100 leituras por parcela. Todas as leituras foram realizadas nos horários entre 10 e 12 horas.

Após a conclusão das leituras, os dados foram organizados, processados e exportados no formato “.txt” pelo software ViewSpec Pro (ASD, 2008), em seguida foram gerados os gráficos para visualização das curvas espectrais a partir da média de dados obtidos por parcela, processados os índices de vegetação e realizadas as análises estatísticas para todas as datas de avaliações.

4.3.2 Coleta de dados com a câmera fotográfica multiespectral e conversão para reflectância

A coleta de imagens foi realizada com duas câmeras fotográficas multiespectrais, modelo Fujifilm S200-EXR (Figura 8), com 12.1 megapixels, equipadas com sensor interno *Charge-Coupled Device* (CCD), com sensibilidade à radiação eletromagnética entre 350 e 1.100 nm (Lebourgeois et al., 2008) e não apresentam filtro interno de bloqueio à radiação infravermelho, o que as difere de câmeras comuns. A resolução radiométrica é 8 bits, portanto, 256 números digitais ou níveis de cinza, distribuídos em três canais: red (vermelho), green (verde) e blue (azul).



Figura 8. Câmera fotográfica multiespectral Fujifilm S200-EXR.

As câmeras foram fixadas em um VANT (Veículo Aéreo Não Tripulado) octocóptero modelo Tarot Iron Man 1.000, composto de fibra de carbono 3k, equipado com motores brushless de 340 KV modelo T-Motor MN5212 e potência de 600 W, com hélices de 17 x 5.5 polegadas (Figura 9), desenvolvido para transportar sensores multiespectrais e hiperespectrais. Este possui capacidade de sustentação de aproximadamente 4 kg, com autonomia de voo de 20 minutos, utilizando bateria de polímero de lítio (Lipo) com capacidade 16.000 maH 6S 22.8V e taxa de descarga de 10C. A altitude de voo foi padronizada para 200 metros em relação ao solo, devido a esta ser uma altitude suficiente para as imagens contemplarem toda área do experimento.

O VANT foi operado por meio de um rádio controle FUTABA de 2.4 ghz com 14 canais. O disparo das câmeras era acionado por um dos canais deste mesmo controle. No VANT foi acoplado um sistema de transmissão de vídeo trabalhando na frequência de 5.8 ghz com 2.000 mW, que transmite a imagem de uma das câmeras em tempo real durante a realização do voo. As informações de telemetria foram obtidas por um “OSD” (On Screen Data). Em solo foi montado o sistema de acompanhamento de voo composto por um receptor de vídeo 5.8 ghz e uma tela LCD de 5 polegadas.

Para garantir a qualidade e padronização das fotos, bem como evitar variações inerentes ao sensor, o foco da câmera foi travado e o balanço de branco foi personalizado para as condições de iluminação do ambiente de aquisição. As câmeras foram configuradas no modo EXR, que controla automaticamente a abertura do diafragma e o tempo de abertura do obturador de acordo com a incidência luminosa, necessário para a sensibilização do sensor CCD, as dimensões das imagens foram ajustadas para tamanho Large 4:3 com 4.000x3.000 pixels, formato RAW e ISO de 800.

As duas câmeras foram posicionadas de forma que coletassem imagens da mesma área simultaneamente, uma das câmeras coletou imagens na região visível do espectro eletromagnético (RGB – Red Green Blue), com auxílio do filtro UV/IR *Cut*, que bloqueia a entrada dos demais comprimentos de onda (ultravioleta e infravermelho – UV/IR), enquanto a outra câmera coletou imagens na região NIR (Infravermelho próximo) do espectro, com auxílio do filtro de 760 nm que bloqueia a entrada de comprimentos de onda inferiores a este.



Figura 9. Veículo aéreo não tripulado utilizado para transporte das câmeras.

Este tipo de equipamento gera como produto uma imagem composta por números digitais (*Digital Numbers - DN*), os quais devem ser convertidos para valores de reflectância quando se tem o objetivo de trabalhar numericamente alguns parâmetros de interesse inerentes a culturas agrícolas. Assim, além das configurações internas das câmeras, as mesmas também precisaram passar pelo processo de calibração e adequação de modelo matemático para conversão dos dados, para que haja robustez e coerência nas informações obtidas.

Para isso, valores de reflectância de alvos conhecidos (gramado, milho, solo e palhada) foram coletados com o espectrorradiômetro e DN dos mesmos alvos foram coletados nas imagens das câmeras digitais, com auxílio da ferramenta ROI, no programa ENVI; estes dados foram correlacionados e geraram modelos de conversão de números digitais para reflectância em cada uma das bandas (vermelho, verde, azul e infravermelho próximo), nos quais foram

aplicados critérios estatísticos para verificação da qualidade dos modelos obtidos (FURLANETTO, 2018). As equações para conversão de números digitais em reflectância estão demonstradas abaixo:

$$a) \hat{y} = 0,05280 \times e^{-0,01390 \times DN}$$

$$b) \hat{y} = -2,68724708 + 0,613383536 \times \ln(DN)$$

$$c) \hat{y} = -10,4328918 + 0,172106012 \times DN - 0,00055304 \times DN^2$$

Em que:

a) É o modelo de regressão exponencial para conversão do DN em reflectância para banda vermelha;

b) É o modelo de regressão quadrática para conversão do DN em reflectância para banda verde, e;

c) É o modelo de regressão quadrática para conversão do DN em reflectância para banda do infravermelho próximo.

4.3.3 Processamento das imagens aéreas

Foram realizadas capturas de várias cenas, e selecionadas imagens com pouca ou nenhuma distorção e iluminação homogênea em toda área de interesse. Em seguida as imagens foram convertidas do formato do formato .RAW para .TIFF com auxílio do software FinePix Viewer. As imagens NIR, além da conversão do formato, também tiveram conversão de sua coloração para preto e branco com objetivo de equalizar o valor de número digital. Em seguida foi realizado o georreferenciamento das imagens com auxílio do software QGIS 3.2.0 e pontos de coordenadas coletados na área experimental. O georreferenciamento das imagens é necessário para que as cenas RGB e NIR se sobreponham no software, buscando unir os mesmos pixels aos mesclar as imagens. Foram coletados 8 pontos de coordenadas de controle nas extremidades da área experimental com o auxílio de um GPS Hiper II (Topcon®). A primeira imagem foi georreferenciada utilizando os pontos de controle, em seguida as demais imagens foram georreferenciadas a partir da cena modelo, identificando na área os objetos sinalizadores dos pontos. Após georreferenciadas, as imagens foram “mescladas” com auxílio do software QGIS, resultando em uma cena de 4 bandas: R-G-B-NIR (Red-Green-Blue-Infravermelho próximo).

Com auxílio do software ENVI 5.3® - Environment for Visualizing Images – SulSoft, foram selecionadas as parcelas uma a uma, coletados e tabulados seus valores de médias de DN em cada uma das bandas, em todas as datas avaliadas. Os valores de DN coletados foram convertidos para reflectância por meio de modelos de calibração desenvolvido para as câmeras (Tópico 4.3.2).

4.4 Obtenção dos índices de vegetação

A partir dos dados de reflectância, foram gerados índices de vegetação que nada mais são do que combinações de bandas espectrais por meio de modelos matemáticos, a fim de realçar características específicas da vegetação sob determinados tipos de manejo. Neste caso, foram testados diferentes índices de vegetação (Tabela 4) com objetivo de quantificar sua sensibilidade na identificação de diferentes níveis de deficiência de P em plantas de milho e constatar o(s) mais representativo(s) para a situação.

Tabela 4. Índices de vegetação utilizados neste trabalho.

ÍNDICE	EQUAÇÃO	REFERÊNCIA
Índice de vegetação por diferença normalizada	$NDVI = \frac{NIR-RED}{NIR+RED}$	Rouse et al. (1974)
Índice de vegetação da diferença de verde normalizado	$GNDVI = \frac{NIR-GREEN}{NIR+GREEN}$	Gitelson et al. (1996)
Razão entre vermelho e infravermelho próximo	$RNIR = \frac{RED}{NIR}$	Richardson e Wiegand (1977)
Razão entre verde e infravermelho próximo	$GNIR = \frac{GREEN}{NIR}$	Bausch e Duke (1996)
Razão entre infravermelho próximo e vermelho	$RVI = \frac{NIR}{RED}$	Birth e Mcvey (1968)
Razão entre infravermelho próximo e verde	$GRVI = \frac{NIR}{GREEN}$	Sripada et al. (2006)

NIR = infravermelho próximo.

Para obtenção dos valores de IV's (tanto do espectrorradiômetro como das imagens), foram selecionados os valores de reflectância dos comprimentos de onda de interesse (vermelho, verde e infravermelho próximo) e mensuradas suas médias em cada parcela experimental. Esses valores de média foram utilizados nas equações.

Os IV's gerados tiveram seus valores testados pelo teste de normalidade de resíduos Shapiro-Wilk e homogeneidade de variâncias Bartlett ao nível de probabilidade de erro (α) de 5%. A partir de constatada a normalidade dos dados, foi realizado o teste de médias T ao nível α 5%.

Os faixas de comprimentos de onda referente a cada banda variam de acordo com a perspectiva de diferentes autores, já que estas mudam de forma gradativa e, portanto, não tem um ponto inicial ou final exato. Neste trabalho, as referências de bandas utilizada foram de acordo com Moreira (2011) e Crusiol (2017), sendo estas:

- Banda Verde (500 – 578 nm);
- Banda Vermelho (620 – 720 nm);
- Banda Infravermelho próximo (760 – 1.000 nm).

4.5 Períodos de avaliações

As avaliações com espectrorradiômetro tiveram início no dia 06/03/19 (30 DAE), seguidas por 37, 53, 66, 73, 80, 92 e 99 DAE, sempre entre os horários de 10 e 12h. Foram realizadas semanalmente até o completo desenvolvimento da espiga, com exceção de semanas nas quais houveram ocorrência de precipitação todos os dias, com o intuito de acompanhar o desenvolvimento das plantas e seus estádios fenológicos. As coletas de cenas com câmera fotográfica multiespectral foram realizadas aos 37, 53, 66, 73, 80 e 92 DAE, sempre entre 12h e 14h. A iluminação solar deve estar homogênea por toda a área experimental.

4.6 Análise foliar nutricional

A amostragem de folhas para análise foliar nutricional ocorreu no dia 25/04/19. Foram coletadas 5 folhas representativas das parcelas experimentais, em seguida foram lavadas com água deionizada, secas em estufa de circulação forçada de ar na temperatura de 65°C até peso constante e trituradas em moinho Wiley.

Foi realizada a digestão de 500 mg das amostras com solução nitro-perclórica, seguido por transferência para um balão volumétrico de 50 mL, o qual teve seu volume completado por água deionizada, conforme MALAVOLTA et al. (1997). Em seguida, foram determinados os teores de nutrientes foliares a partir do sistema 4200 MP-AES, da Agilent Technologies®. Os dados dos nutrientes foliares foram aplicados a técnica de estatística multivariada PLSR para geração de modelos de estimativa de P foliar.

4.7 Análise de solo

Ao final do ciclo da cultura, foi realizada amostragem de solo a partir da coleta de 12 pontos por parcela, distribuídos igualmente na linha e entrelinha, e homogeneização do solo, resultando em uma amostra por parcela experimental. Foram determinados o pH em CaCl_2 0,01 mol L^{-1} e teor de P conforme SILVA et al. (2009).

Os teores de P no solo foram atestados pelos pressupostos de homocedasticidade das variâncias (Bartlett) e normalidade dos dados (Shapiro-wilk) após transformação pelo método de raiz quadrada e submetidos a análise de variância. Em seguida foi realizada a análise de regressão para verificar a relação entre os níveis de adubação e teor de fósforo no solo, a qual foi avaliada pelo coeficiente de determinação R^2 .

4.8 Obtenção de dados de produtividade

A colheita foi realizada no dia 25/06/2019, de forma manual, compreendendo três linhas centrais da parcela (área útil), a fim de evitar efeito de bordadura. Foi realizada pesagem do montante de grãos obtidos por parcela, bem como mensuração da umidade, e calculados valores de produtividade por parcela experimental.

Os dados foram atestados pelos pressupostos de homocedasticidade das variâncias (Bartlett) e normalidade dos dados (Shapiro-wilk) e submetidos a análise de variância, que resultou em diferença significativa entre os tratamentos ($p \leq 0,05$) para ambos os experimentos, os quais são representados por duas diferentes fontes de adubo fosfatado: Monoamônio Fosfato e Superfosfato Simples. Em seguida procedeu-se o teste t para comparação das médias, ao nível de 5% de probabilidade de erro.

4.9 Análise estatística multivariada

4.9.1 Modelos lineares discriminantes

Para obtenção dos modelos lineares discriminantes foi utilizado o software SAS 9.4. Inicialmente foi utilizado o procedimento PROC STEPDISC, o qual realiza uma análise discriminante gradual a partir de variáveis dependentes e independentes para selecionar subconjuntos das variáveis independentes que melhor representam a discriminação entre as classes. Assim, foram selecionados comprimentos de onda que melhor representam os tratamentos aqui estudados.

Este procedimento envolve o critério de seleção de variáveis pelo método conhecido por STEPWISE, que é uma combinação dos procedimentos *forward* e *backward* onde as variáveis

dão entrada no modelo uma-a-uma, de acordo com o valor de Lambda de Wilk's, seguindo o critério da razão de verossimilhança, e o valor de F parcial de entrada em cada estágio (KARIMI et al., 2005). Os valores de lambda de Wilk's foram indicativos da separabilidade ou do poder discriminatório dos comprimentos de onda, ou seja, quanto menor o valor de lambda de Wilk's, maior a diferenciação espectral entre os tratamentos (THENKABAIL et al., 2004).

A seleção *forward* começa sem variáveis no modelo e a cada etapa do PROC STEPDISC, entra a variável que mais contribui para o poder discriminatório do modelo, neste caso, medido pelo valor de F parcial obtido através de uma análise de variância para cada uma das n-variáveis candidatas a entrar no modelo separadamente. Caso ocorra a entrada de alguma variável, o algoritmo inicia a análise sobre uma outra nova variável candidata a entrar no modelo por meio da comparação dos valores de F parciais para esta nova variável, sendo comparado com um valor de referência escolhida inicialmente, determinante para a entrada ou não da mesma. Quando nenhuma das variáveis não selecionadas atende ao critério de entrada, o processo para.

Já o procedimento *backward* começa com todas as variáveis do modelo e em cada etapa, a variável cujo valor F parcial seja menor que o F de referência, é removida. O processo reinicia e quando todas as variáveis restantes atendem ao critério para permanecer no modelo, o processo de eliminação para. Neste trabalho, foi adotado 10% de probabilidade de erro para execução do procedimento, tanto para a entrada como saída das variáveis.

Para realização do procedimento foram utilizados os comprimentos de onda entre 450 a 1.000 nm, sendo estas as bandas consideradas mais representativas para culturas (CRUSIOL, 2017; FURLANETTO, 2018; GASPAROTTO, 2014; MUÑOZ-HUERTA et al., 2013; PINTER JR et al., 2003). Ao final do procedimento o programa disponibiliza uma tabela que demonstra as variáveis que melhor explicam os tratamentos, além de parâmetros de análise destas, sendo estes os valores de F, Lambda de Wilk's, p-valor e outros critérios para interpretação.

O procedimento STEPDISC é uma etapa anterior a análises adicionais. Neste caso, em seguida foi utilizado o procedimento PROC DISCRIM para elaboração de uma modelo linear discriminante a partir das bandas selecionadas pelo procedimento anterior. Esse modelo deve permitir a classificação de novos indivíduos (em condições semelhantes a estes) aos diferentes grupos de tratamentos aqui estudados. Para tanto, o procedimento gerou funções discriminantes para cada tratamento através de combinações lineares das variáveis preditoras (comprimentos de onda) (KARIMI et al., 2005).

Com o objetivo de reforçar a análise discriminante, foi realizada uma simulação no SAS, na qual apenas 60% dos dados espectrais foram utilizados na geração de um modelo discriminante para cada tratamento, o qual foi testado pelos 40% restantes. Os dados foram selecionados de forma aleatória pelo software. O procedimento de simulação foi repetido 60 vezes, conforme programado no software, ou seja, o sistema escolheu aleatoriamente 60% dos dados para geração do modelo de discriminação e 40% para teste, por sessenta vezes consecutivas. O sistema disponibiliza parâmetros de avaliação para a classificação, dentre estes se encontram o teste Qui-quadrado e coeficiente de contingência r .

4.9.2 Análise de regressão pelo método dos mínimos quadrados parciais (PLSR)

Foi utilizada a análise Partial Least Square Regression (PLSR) ou regressão pelo método dos mínimos quadrados parciais, para elaborar modelos de predição de fósforo foliar e produtividade da cultura de milho a partir de seus dados de reflectância espectral. Para tanto, foi utilizado o software The Unscrambler® (CAMO Software - Norway).

Para predição de P foliar, foram utilizados os comprimentos de onda de 450 a 1.000 nm, totalizando 550 bandas como variáveis independentes, e os valores de fósforo foliar obtidos de cada parcela como variáveis dependentes. A coleta de amostras para análise foliar e dos dados espectrais aqui utilizados foram realizadas no mesmo dia, cuja cultura se encontrava em estágio R3. O período para amostragem foliar com objetivo de análise foliar nutricional recomendado para milho é em estágio R1 (SBCS/NEPAR, 2017), contudo, condições climáticas ocasionaram o atraso na amostragem, visto que esta deveria ser no mesmo dia da coleta de dados espectrais para comparação efetiva dos dados, e que o sensor hiperespectral não pode ser exposto a umidade excessiva.

Quanto a predição de produtividade, foram utilizados também os comprimentos de onda de 450 a 1.000 nm, totalizando 550 bandas como variáveis independentes, e valores de produtividade de cada parcela como variáveis dependentes. Os dados de produtividade foram obtidos a partir da coleta de grãos ao final do ciclo da cultura, enquanto os dados espectrais utilizados foram referentes aos estádios V6, V7 e VT da cultura, com objetivo de observar qual destes estádios melhor auxilia na predição da variável.

Considerando que o objetivo desta análise foi elaborar e avaliar modelos de predição de fósforo foliar e produtividade a partir de dados de reflectância espectral de plantas de milho submetidas a diferentes níveis nutricionais de adubo fosfatado, independente de qual seja sua fonte, nesta etapa os dados dos dois experimentos foram utilizados simultaneamente. Assim,

foi utilizado o tratamento testemunha, somado às quatro doses de adubação de cada experimento (e quatro repetições para cada), totalizando 36 amostras (parcelas).

Para construção do modelo, inicialmente foram selecionadas 28 amostras para calibração e validação cruzada dos dados e 8 amostras para etapa de predição de dados. As amostras foram selecionadas aleatoriamente. Este método modela as variáveis dependentes e independentes simultaneamente na construção do modelo, obtendo novas variáveis denominadas como fatores latentes, que são variáveis encontradas nos valores X (comprimentos de onda) que melhor predizem os valores Y (fósforo foliar ou produtividade) (BARMEIER et al., 2017).

Após gerado o modelo, a distribuição dos dados foi avaliada pelas ferramentas Hotelling's T^2 (a 5% de probabilidade de erro) e Leverage, utilizados na identificação de outliers, os quais devem ter seus dados e influência avaliados para tomada de decisão de manter ou retirar a amostra da construção do modelo.

Os parâmetros utilizados para avaliação do modelo são RMSE e R^2 , os quais são disponibilizados pelo software para todas as etapas. Menores valores em RMSE e maiores valores em R^2 indicam qualidade do modelo obtido (BARMEIER et al., 2017; SHARABIAM et al., 2014; ZHANG e HE, 2013).

No processo de validação cruzada, as mesmas amostras que compõem o modelo são utilizadas para testá-lo. Para tanto, são alternadas retiradas de amostras, as quais tem seus valores previstos pelo modelo. Nesta etapa, o sistema foi configurado para retirar uma amostra por vez. Todos os resíduos de previsão são combinados para calcular a variação residual da validação e assim gerados os valores dos parâmetros de avaliação.

Após a etapa da validação cruzada utilizando 28 amostras, o modelo foi testado avaliando a capacidade de predição de novas amostras a partir de dados que não participaram na construção do modelo PLSR (8 amostras). Os valores de RMSE e R^2 também foram utilizados para avaliação da qualidade e precisão da predição de dados.

Na etapa de predição, o procedimento disponibiliza uma tabela com valores de referência utilizados nas variáveis Y, bem como os valores preditos pelo modelo para cada uma delas, os quais foram utilizados para interpretação e avaliação do potencial de utilização de dados de reflectância espectral na predição de parâmetros agronômicos de culturas.

5. RESULTADOS E DISCUSSÃO

5.1 Teor de fósforo no solo

A análise de variância dos dados de teor de P no solo resultou em diferença significativa entre os tratamentos ($p \leq 0,05$) para ambos os experimentos, os quais são representados por duas diferentes fontes de adubo fosfatado: monoamônio fosfato e superfosfato simples. Considerando a influência das doses crescentes dos adubos fosfatados sobre a variável analisada, foi realizada a análise de regressão para verificar a relação entre os níveis de adubação (variável independente) e teor de fósforo no solo (variável dependente), para ambos os experimentos (Figura 10).

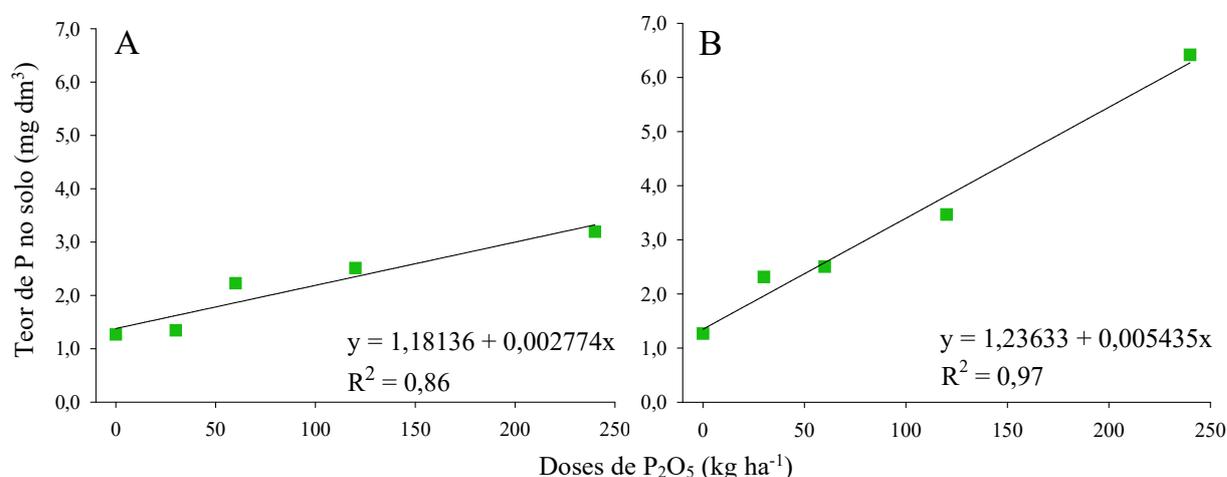


Figura 10. Análise de regressão para teores de P no solo em função dos insumos aplicados. A: parcelas com utilização de adubo fosfatado MAP (Monoamônio Fosfato); B: parcelas com utilização de adubo fosfatado SS (Superfosfato Simples). Doses de 0, 30, 60, 120, 240 kg ha⁻¹ P₂O₅ referente aos tratamentos T1, T2, T3, T4, T5, respectivamente, para ambos os adubos).

Referente ao experimento com fertilizante MAP, foi observada resposta de regressão linear para os teores de P no solo, cujo coeficiente de determinação da equação (R^2) indica que 86% da variável analisada está sendo explicada pelo modelo encontrado (Figura 10-A). Como esperado, o tratamento testemunha (T1) o qual é representado pela ausência de adubo fosfatado, apresentou o menor valor quanto ao teor de P (1,27 mg dm⁻³), seguido por valores crescentes da variável analisada, de acordo com a respectiva ordem dos tratamentos (T2, T3, T4 e T5 com valores de 1,34, 2,22, 2,51 e 3,19 mg dm³, respectivamente).

O fertilizante SS também apresentou resposta linear para os teores de P no solo e coeficiente de determinação ainda maior, com 97% da variável sendo explicada pelo modelo (Figura 10-B). Essa resposta linear tem início com o tratamento testemunha respondendo como

o menor valor da variável teor de P no solo, e segue com valores aumentando de forma gradativa no decorrer dos tratamentos (T1, T2, T3, T4 e T5 com valores de 1,27, 2,31, 2,50, 3,46 e 6,41 mg dm³, respectivamente), de acordo com a dose de fertilizante aplicada.

Apesar da comparação estatística entre os experimentos não fazer parte dos objetivos deste trabalho, não se pode deixar de notar a diferença numérica da disponibilidade de fósforo no solo observada na Figura 10, cujos tratamentos referente a fonte SS, em sua maioria, chegaram a apresentar o dobro do valor de teor de P no solo quando comparados aos tratamentos referente a fonte MAP.

O fertilizante monoamônio fosfato possui solubilidade de aproximadamente 44% em água, enquanto isso, o fertilizante superfosfato simples possui cerca de 16% de solubilidade em água (Anexo I IN MAPA n° 39, 2018). Considerando a proporção de solubilidade das duas fontes, provavelmente a fonte de maior solubilidade (MAP) foi rapidamente disponibilizada e, portanto, exposta a interações com as partículas coloidais do solo, bem como absorção pela cultura de milho safrinha, ao passo que a fonte de menor solubilidade (SS) liberou gradativamente seus componentes, permitindo que estes também participassem de interações com solo e planta e ainda tivessem seu residual observado na análise de solo.

A retenção do P adicionado ao solo, em formas lábeis ou não, ocorre tanto pela precipitação do P em solução com formas iônicas de Fe, Al e Ca, como, principalmente, pela sua adsorção pelos oxidróxidos de Fe e Al (Novais e Smyth, 1999), minerais estes que predominam no Latossolo. A reação de fosfatos com esses metais pode se dar na solução do solo, com formação de compostos insolúveis, ou pode ocorrer na superfície das partículas da fração argila, nesse caso, a ligação é do tipo covalente ou troca de ligantes, isto é, o P é adsorvido especificamente, em processo não reversível (RAIJ, 2011). Assim, embora o P ligado seja bastante abundante em muitos solos, está amplamente indisponível para captação, sendo frequentemente o elemento mais limitante para o crescimento e desenvolvimento das plantas (VANCE et al., 2003).

Caione et al. (2013) trabalhando com diferentes fontes de adubo fosfatado em cultura de cana-de-açúcar, também observaram que fertilizantes com característica de alta solubilidade disponibilizam o P no solo de forma mais rápida, apresentando pouco residual na análise de solo. Em seu trabalho, após a colheita da 1ª e 2ª soca da cultura, os teores do adubo superfosfato triplo (42,5% de solubilidade) no solo não diferiram estatisticamente da testemunha, enquanto isso, o fertilizante Arad (10,4% de solubilidade) apresentou teores significativamente maiores

que a testemunha, considerando que ambos os adubos tiveram a mesma dose de P_2O_5 aplicadas no sulco de plantio de cada tratamento (100 kg ha^{-1}).

Outros autores também confirmaram a influência da solubilidade de adubos fosfatados na disponibilidade de seus componentes, bem como efeitos decorrentes deste fato sobre a produção de culturas, desde décadas atrás até trabalhos atuais (CARVALHO et al., 2017; COUTINHO et al. 1991; CRUZ et al., 2018; HAGIN e BERKOVITS, 1961; OLIVEIRA et al., 2012; SOUZA et al., 2018).

Segundo-Urquiaga et al. (1982) encontraram um efeito residual significativo da adubação fosfatada equivalente a 2,3 vezes maior que o fósforo natural do solo para ambas as fontes de seu estudo, aplicando 80 kg ha^{-1} de P_2O_5 em função da solubilidade dos fertilizante araxá (4% de solubilidade e 34,6% P_2O_5) e superfosfato simples (20% de P_2O_5 solúvel) por três anos consecutivos, em cultivo de feijão.

Portanto, observa-se que a adubação é realizada com a expectativa de aumento de produtividade, que por sua vez é a fonte de lucro do agricultor. Contudo, é necessário o conhecimento das características do adubo, solo, cultura e interação entre estes, para que a adubação tenha resultados efetivos.

5.2 Comportamento espectral do milho sob diferentes doses de P e datas de avaliações

Os procedimentos utilizados para obter dados de nutriente foliar em culturas, comumente utilizam amostras vegetais para aquisição das informações, o que demanda grande quantidade de mão-de-obra para amostragem e processamento da análise, sendo um processo oneroso e dispendioso. Assim, pesquisadores têm estudado técnicas de sensoriamento remoto na tentativa de monitorar o status nutricional de culturas a partir de sua resposta espectral perante diferentes níveis nutricionais (Chicati, 2015; Furlanetto, 2018; Gasparotto, 2014; Muñoz-Huerta et al., 2013; Osborne et al., 2002), uma vez que demanda reduzida quantidade de pessoal, além da ausência de necessidade de extrair material vegetal.

Na Figura 11 são apresentadas as curvas espectrais do milho nos estádios de desenvolvimento V6, V7, VT, R1, R2, R3, R4 e R5, aos 30, 37, 53, 66, 73, 80, 92 e 99 DAE, respectivamente, e suas características influenciadas por diferentes doses do adubo fosfatado monoamônio fosfato.

Desde o estágio V6 até R3, foi observado tendência de comportamento espectral semelhante, representado por diferença evidente nos valores de fator de reflectância na região visível do espectro eletromagnético, onde os tratamentos T1 e T2 (0 e $30 \text{ kg ha}^{-1} P_2O_5$,

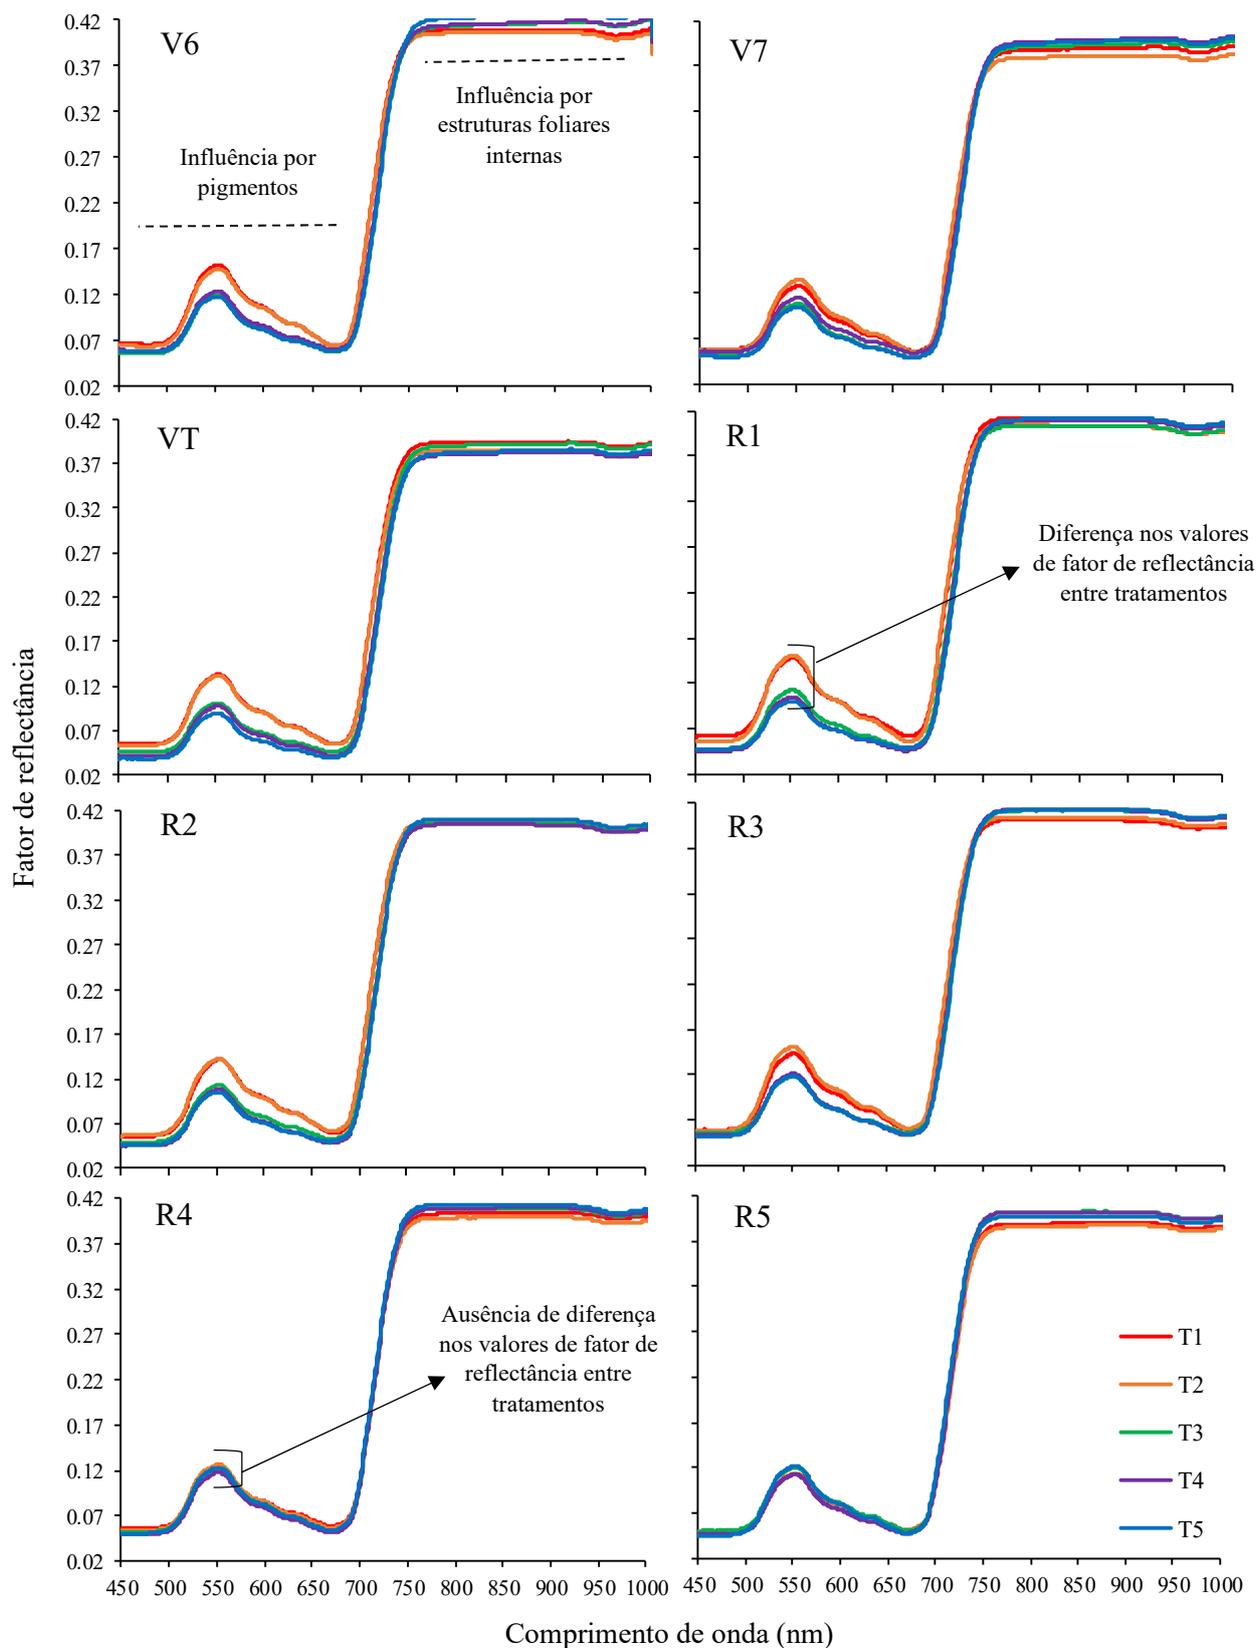


Figura 11. Fator de reflectância médio dos tratamentos, obtido por espectrorradiômetro na cultura de milho em diferentes estádios de desenvolvimento, referente ao experimento com fertilizante fosfatado MAP.

respectivamente) apresentaram os maiores valores desta variável analisada (fator de reflectância) quando comparados aos demais tratamentos (T3, T4 e T5 com 60, 120 e 240 kg ha⁻¹ P₂O₅, respectivamente). Esse valor de reflectância superior observado nos tratamentos 1 e 2, provavelmente ocorreu como resposta ao estresse da planta devido as condições limitantes de nutrição de P, conforme será discutido a seguir.

As folhas das plantas exibem, tipicamente, reflectância muito baixa na região visível do espectro eletromagnético devido à forte absorção luminosa pelos pigmentos. Segundo Gasparotto (2014), a faixa visível do espectro corresponde a resposta espectral dos pigmentos das folhas existentes nos cloroplastos, onde a clorofila é a grande responsável pela absorção da radiação eletromagnética (REM). As plantas absorvem a REM eficientemente em todo o ultravioleta e nas regiões visíveis do espectro, onde a energia é absorvida seletivamente pela clorofila e é convertida em calor ou fluorescência, e também convertida fotoquimicamente em energia estocada na forma de componentes orgânicos por meio da fotossíntese (GATES et al., 1965; PONZONI, 2002).

As folhas contêm clorofila *a* e *b* como pigmentos essenciais para a conversão de energia luminosa em energia química armazenada e a quantidade de radiação solar absorvida por uma folha é uma função do conteúdo do pigmento fotossintético em determinadas bandas (HATFIELD et al., 2008).

Na região do violeta ao ciano, as clorofilas e carotenoides são responsáveis pela absorção da REM, enquanto na região do verde a absorção se deve ao teor de clorofila e espessura da folha, e na região do vermelho apenas as clorofilas influenciam na absorção (FALCIONI et al., 2017). A absorção no azul e vermelho é sempre alta, apresentando suaves diferenças em folhas com baixo conteúdo de pigmentos, e está relacionada a primeira camada do parênquima paliçádico, enquanto isso, a região do verde tem a absorção proporcional à quantidade de clorofila, e a REM é absorvida mais eficientemente por folhas mais espessas, devido as estruturas adicionais de captação de luz, visto que a absorção da luz verde pelas clorofilas é pouco eficiente (FALCIONI et al., 2017; MORIWAKI et al., 2019).

O estresse de plantas e/ou a senescência natural de fim de estação normalmente resultam em menores concentrações de clorofila que permitem a expressão de pigmentos foliares acessórios, como carotenos e xantofilas (PINTER JR et al., 2003). Isso tem o efeito de ampliar o pico de reflexão verde (normalmente localizado próximo a 550 nm) em direção a comprimentos de onda maiores, aumentando a reflectância visível (ADAMS et al., 1999). Além disso, o considerável aumento de reflectância na região do visível para plantas sob deficiência

nutricional de P observados neste trabalho, provavelmente têm também grande influência da estrutura foliar e acúmulo de amido.

Plantas com sintomas de deficiência de fósforo apresentam menor espessura de estruturas foliares, células de tamanho menor e tamanho da planta reduzido, devido ao comprometimento de inúmeros processos metabólicos do qual o nutriente participa (FAQUIN, 2005; JACOB e LAWLOR, 1991; PERRENOUD, 1990). Segundo Falcioni et al. (2017), a espessura das folhas e do parênquima esponjoso é um fator essencial na absorção de luz verde. Estes autores encontraram valores de correlação significativos entre a absorção da luz verde e espessura da folha, concluindo que a luz verde é fracamente absorvida pelos cloroplastos e assim, exige folhas mais espessas para ser absorvida com mais eficiência. Assim, plantas sob deficiência nutricional de P tendem a apresentar maiores valores de reflectância na região do visível, em especial na banda verde, conforme observado na Figura 11.

A luz verde impulsiona a fotossíntese mais profundamente na folha, em regiões como o parênquima esponjoso, que não é saturado ou então atingido pelas luzes vermelha ou azul (TERASHIMA et al., 2009). Os autores ainda citam que o menor coeficiente de absorção da luz verde pelas clorofilas e sua eficácia no processo de fotossíntese sugere que mudanças estruturais no parênquima paliçádico e esponjoso são cruciais para maximizar a eficiência da captura desta luz.

Quanto ao acúmulo de amido nas folhas, plantas sob baixo suprimento de fósforo, em geral, apresentam esta característica. O Pi (fósforo inorgânico) no citosol e as trioses-fosfato no cloroplasto trocam de lugar de forma simultânea, obrigatoriamente, assim, a ausência ou pequena quantidade de Pi no citosol limita a exportação de triose-fosfato para o citosol, a qual continua sendo utilizada para formação de amido. Devido à inibição da exportação de trioses-fosfato do cloroplasto, o acúmulo de grandes quantidades de amido nos cloroplastos é uma característica típica da deficiência de P (MARSCHNER, 2012). Assim, este acúmulo de amido provavelmente influencia na maior reflectância das folhas na região do visível, contudo, mais estudos são necessários sobre esta propriedade.

O fósforo desempenha um papel em uma matriz de processos, incluindo geração de energia (síntese de ATP – adenosina trifosfato), síntese de ácido nucleico, fotossíntese, glicólise, respiração, síntese e estabilidade de membranas, ativação e inativação enzimática, reações redox, sinalização, metabolismo de carboidratos e fixação de nitrogênio (N) (VANCE et al., 2003). Assim, sua disponibilidade na solução do solo é fundamental para suprir as necessidades das plantas, participando do equilíbrio nutricional. Na Figura 12 pode ser

observado um exemplo da diferença de desenvolvimento entre plantas a partir de níveis de adubo fosfatado aplicado ao solo.

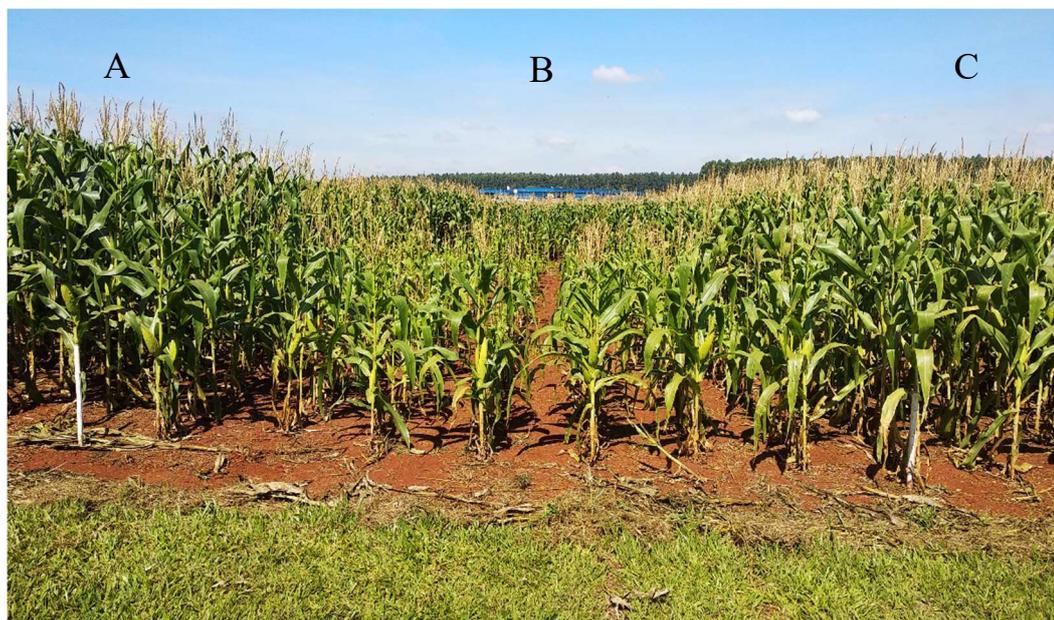


Figura 12. Desenvolvimento da cultura de milho safrinha em função de diferentes níveis do adubo fosfatado MAP. A: 60 kg ha⁻¹ P₂O₅; B: 0 kg ha⁻¹ P₂O₅; C: 240 kg ha⁻¹ P₂O₅.

Além disso, a semelhança na tendência de comportamento espectral dentre os estádios de V6 a R3, confirma a influência do P na planta desde fases mais jovens até estádios reprodutivos avançados.

Nos estádios V7, VT e R1 pôde-se visualizar suaves diferenças entre os tratamentos T3, T4 e T5 (Figura 11) na região do visível, os quais mantém a tendência de menor fator de refletância para o tratamento com maior dose de adubação (T5), seguido por valores crescentes em T4 e T3, indicando que essas fases são sensíveis às doses de adubação a ponto de representar as diferenças em seus espectros de reflectância, provavelmente devido a ser o período de acumulação do nutriente nas folhas. Segundo Borges (2006) o acúmulo de P nas folhas é crescente até o período compreendido entre o final do florescimento e o início do enchimento de grãos, nesse período é atingido o ponto máximo de acúmulo nas folhas.

Nos estádios de desenvolvimento R4 e início de R5, não foi observada diferença visual significativa na região do visível, entre os tratamentos. Provavelmente, a diminuição da concentração de clorofila nas folhas promovida pela senescência natural de final de ciclo da cultura fez com que a reflectância dos tratamentos com maiores níveis de adubação (T3, T4 e T5), se tornasse semelhante aos tratamentos mais debilitados (T1 e T2).

Ao contrário da região visível, na região do infravermelho próximo foi observada maior reflectância pelas plantas cujos tratamentos proporcionavam melhores condições de adubação

de P, provavelmente devido as condições das estruturas foliares internas providas pelos diferentes níveis de status nutricional.

A reflectância varia levemente no NIR, principalmente devido à estrutura interna das folhas (forma e tamanho da célula, bem como quantidade de espaço intercelular) e alterações de espessura (GATER et al., 1965; HATFIELD et al., 2008). Assim, quanto mais lacunosa for a região interna da folha, maior será o espalhamento interno de luz e, conseqüentemente, maior a reflectância. Considerando que baixo suprimento de P acarreta diminuição das estruturas foliares (Jacob e Lawlor, 1991), é de se esperar que tratamentos debilitados apresentem menor reflectância na região NIR.

Pinter Jr et al. (2003) cita que o estresse ou então a senescência natural das plantas diminui a reflectância na região NIR. Segundo Perrenoud (1990) plantas com sintomas de deficiência nutricional apresentam tecidos menos enrijecidos, como consequência da menor espessura da cutícula e da parede celular. Essa característica pode ter permitido maior transmitância da REM e, portanto, menor reflectância. Contudo, são necessários mais estudos voltados para esta propriedade.

Na Figura 13 são apresentadas as curvas espectrais do milho nos estádios de desenvolvimento V6, V7, VT, R1, R2, R3, R4 e R5, aos 30, 37, 53, 66, 73, 80, 92 e 99 DAE, respectivamente, e suas características influenciadas por diferentes doses do adubo fosfatado superfosfato simples.

Para este experimento foram observados padrões semelhantes ao experimento anterior, confirmando que realmente referem-se a características da planta perante níveis de nutrição por fósforo. Desde o estádio V6 até R2, foi observado um padrão de comportamento espectral, representado por diferença evidente nos valores de fator de reflectância na região visível do espectro eletromagnético.

Neste experimento, apenas o T1 ($0 \text{ kg ha}^{-1} \text{ P}_2\text{O}_5$) apresentou valores maiores da variável analisada (reflectância), na região do visível, quando comparado aos outros tratamentos (T2, T3, T4 e T5 com 30, 60, 120 e $240 \text{ kg ha}^{-1} \text{ P}_2\text{O}_5$, respectivamente), indicando que nos demais tratamentos as plantas responderam de forma semelhante entre si aos diferentes níveis de adubo fosfatado que receberam. Apenas em V7 pode ser notada suave diferença entre os tratamentos com adubação, indicando este ser um período sensível na distinção espectral perante os tratamentos aqui utilizados.

Conforme foi visto no item 5.1 deste trabalho, tal condição provavelmente ocorra devido a solubilidade da fonte de adubo superfosfato simples, que leva a gradual e prolongada

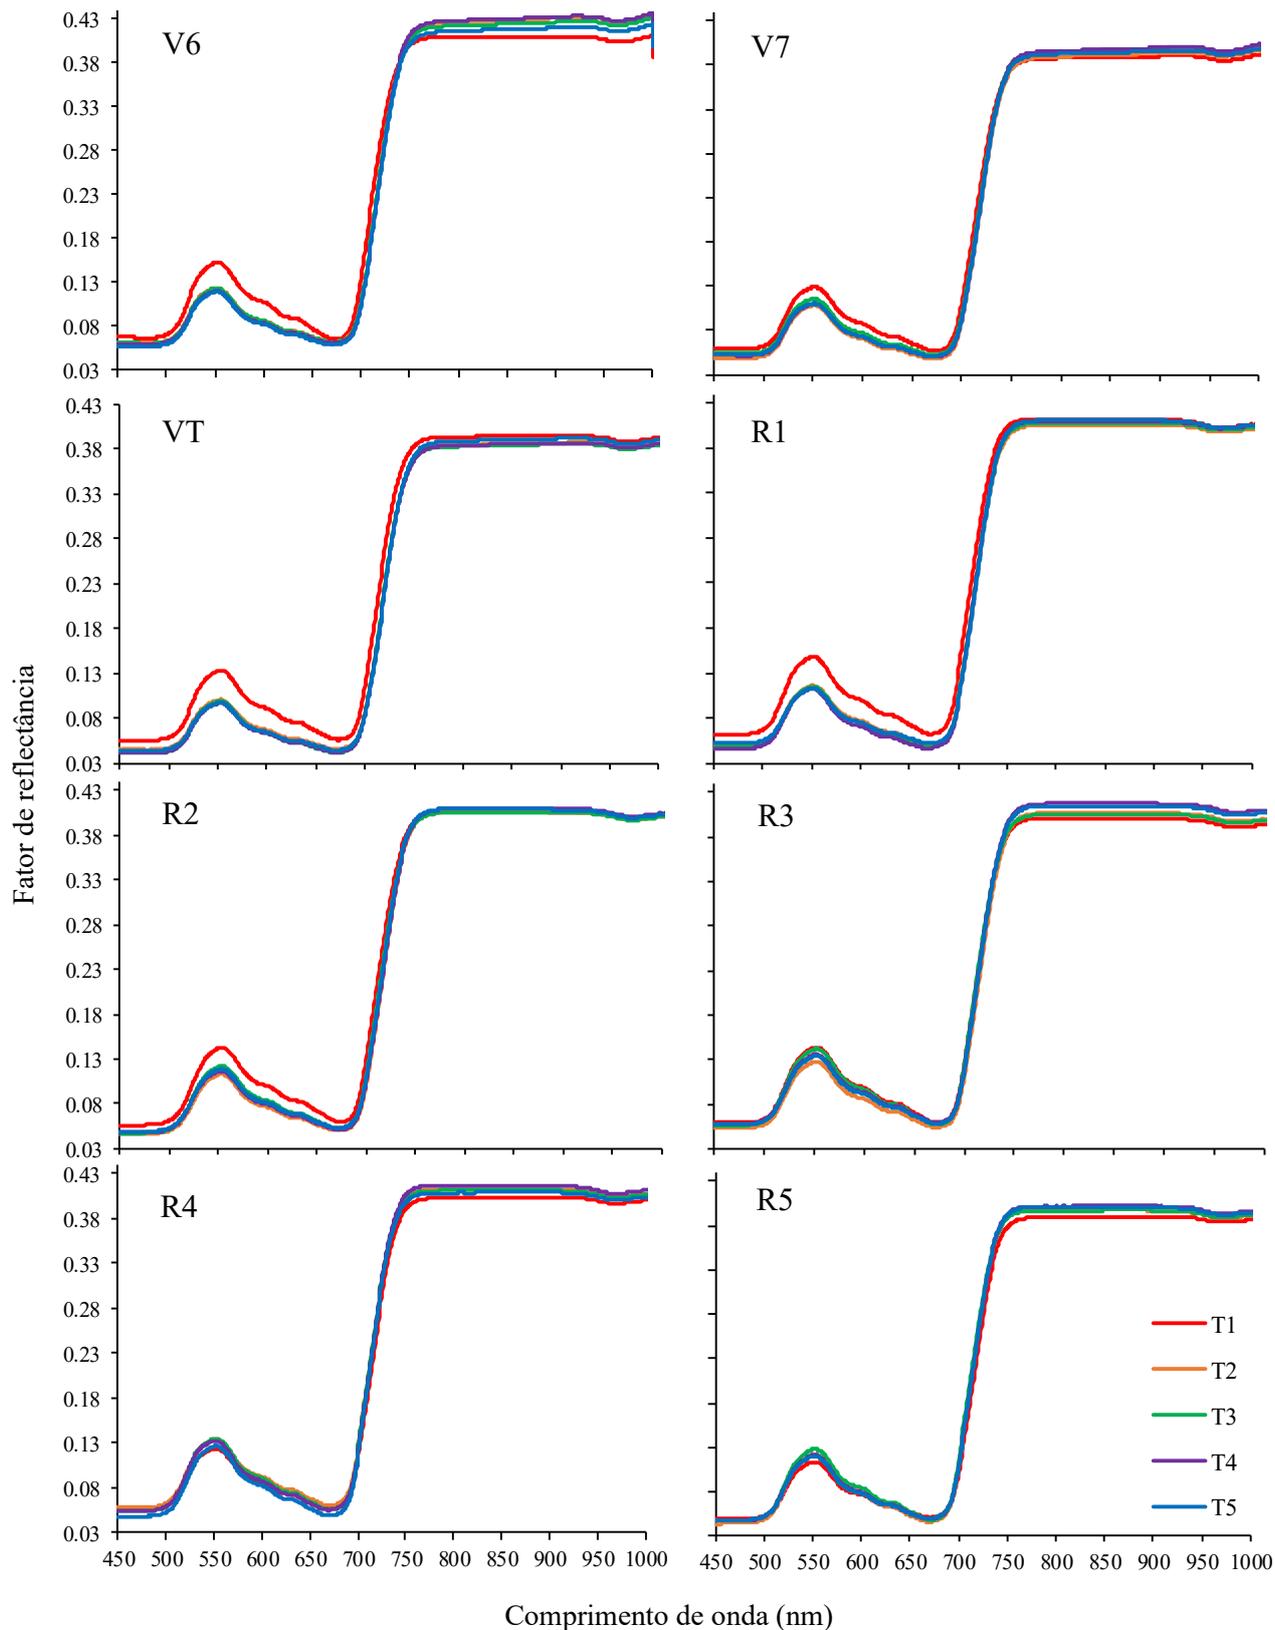


Figura 13. Fator de reflectância médio dos tratamentos, obtido por espectrorradiômetro na cultura de milho em diferentes estádios de desenvolvimento, referente ao experimento com fertilizante fosfatado SS.

disponibilidade dos nutrientes no solo e, portanto, melhor aproveitamento destes pelas plantas mesmo na menor dose aplicada neste experimento.

Nos estádios R3, R4 e início de R5, não foi observada diferença visual significativa na região do visível entre os tratamentos, e as leves diferenças demonstradas apresentaram confusão na ordem dos tratamentos, provavelmente devido a senescência natural de final de ciclo da cultura, bem como translocação de nutrientes para os grãos (Magalhães e Durães, 2006), indicando que estes períodos não são mais válidos na caracterização espectral dos tratamentos aqui trabalhados. Para essa fonte de adubo utilizada, a diferença espectral entre tratamentos, bem como as características das quais provém tais diferenças, ocorreram até o estádio R2.

Na região do infravermelho próximo também foi observada maior reflectância das plantas à medida que os tratamentos proporcionavam melhores condições de nutrição de P. Para os dois experimentos foi notado que o estádio R2 apresentou a menor diferença visual na região do NIR, dentre os tratamentos. Considerando que esta foi a única data que diferiu do padrão das demais, é provável que essa característica observada seja inerente à planta em função de seu estádio.

Gasparotto (2014), trabalhando com doses de nitrogênio em cultura de milho, observou que o comportamento espectral da cultura cultivada sob baixa ou nenhuma dose do elemento apresentou aumento da reflectância nos comprimentos de onda referente a região visível do espectro eletromagnético e diferenças muito pequenas na região do infravermelho próximo. Furlanetto (2018) analisando o comportamento espectral de plantas de milho sob diferentes níveis de adubação potássica, observou aumento da reflectância na região visível do espectro e diminuição do valor de reflectância em NIR para o tratamento representado por maior deficiência de potássio em plantas de milho, especialmente aos 35 DAE.

Até este momento, poucos trabalhos buscaram estudar o comportamento espectral de culturas perante níveis de adubo fosfatado. Dentre estes, estudando a resposta espectral de amendoim em diferentes estádios, em função da interação entre doses de cálcio e adubo fosfatado, Freire (2004) concluiu que as respostas espectrais sofrem mudança nos valores de reflectância conforme as variações das doses dos nutrientes aplicados ao solo, principalmente na região do visível. Enquanto isso, Osborne et al. (2002) cita que a região do infravermelho próximo auxilia na predição de estresse por baixa quantidade de P, principalmente nos estádios de desenvolvimento iniciais (V6 e V8).

5.3 Funções discriminantes elaboradas a partir de dados espectrais coletados pelo espectrorradiômetro

Foi realizada análise discriminante como ferramenta de comparação e análise das respostas espectrais da cultura de milho em função de diferentes níveis de nutrição por adubo fosfatado, com o objetivo de identificar as bandas que melhor caracterizam esta variável em estudo. Em seguida, as bandas selecionadas foram utilizadas para desenvolver funções discriminantes que representassem a diferença entre os grupos e favorecessem a classificação de indivíduos em condições similares. A análise discriminante tem por objetivo identificar as variáveis que distinguem determinados grupos, de modo que conhecendo suas características, seja possível prever a qual grupo pertencem (PESTANA e GAGEIRO, 2005).

Deste modo, foi dada entrada de 550 bandas espectrais coletadas pelo sensor Fieldspec, estabelecidas entre os comprimentos de onda de 450 a 1000 nm. Ao aplicar esse procedimento para o experimento referente a fonte de adubo MAP, 12 bandas foram selecionadas pela ferramenta proc STEPDISC do software SAS ao nível de significância de 10% (Furlanetto, 2018). Os comprimentos de onda selecionados (coluna “entrada”) e demais parâmetros de estatística multivariada utilizadas na diferenciação entre os tratamentos estudados estão apresentados na Tabela 5. Os dados são referentes ao estágio V6 da cultura.

Conforme observado na Tabela 5, os comprimentos de onda selecionados e que melhor caracterizam os tratamentos foram encontrados na região do azul, vermelho e infravermelho próximo. As bandas que atingiram maior significância pela seleção STEPDISC se encontram na região do vermelho e início do infravermelho próximo, dentre os 12 comprimentos de onda selecionados. Bogrekci et al. (2005) estudando concentração de P em instalações agrícolas a partir de dados hiperespectrais, observou comprimentos de onda com alta correlação entre reflectância e concentração de P no intervalo de 650 a 700 nm.

Como observado na Figura 11 do tópico 5.2, visualmente a banda verde (\cong 500 a 578 nm) apresenta diferença significativa entre os tratamentos, assim, era esperado que alguns dos comprimentos de onda que a compõe estivesse dentre as bandas selecionadas por este procedimento, contudo, isso não ocorreu. Analisando detalhadamente cada repetição das bandas dentro dos tratamentos e dentre tratamentos, foi possível notar que as bandas em geral respondem de forma padrão as condições impostas por este experimento, com exceção da banda verde, que apresentou maior variabilidade no fator de reflectância. Segundo Hatfield et al. (2008) a região do verde (\cong 530 a 590 nm) e a região red-edge (\cong 700 nm) apresentam maior

sensibilidade de reflectância ou absorção à variação do pigmento. Provavelmente pela grande variação dos dados, essa região não apresentou significância para o teste em questão.

Tabela 5. Bandas espectrais selecionadas para participação na construção de modelos discriminantes lineares a partir de curvas espectrais de milho em função de doses de adubo fosfatado MAP, obtidas pelo espectrorradiômetro.

Etapa	Entrada	Pr > F	Wilk's Lambda	Q.M. correlação canônica	Pr > QMCC ¹
1	608	0,0162	0,2134319	0,24504385	<,0001
2	696	0,0585	0,2086571	0,2503939	<,0001
3	450	0,0273	0,184781	0,26279591	<,0001
4	781	0,0354	0,1645527	0,28654885	<,0001
5	742	0,0044	0,1385616	0,31616007	<,0001
6	782	0,0583	0,1273705	0,33283658	<,0001
7	607	0,0586	0,1232076	0,33701791	<,0001
8	614	0,0755	0,1117618	0,35526005	<,0001
9	622	0,0075	0,1029025	0,3690347	<,0001
10	619	0,0471	0,0958645	0,38178381	<,0001
11	665	0,0804	0,0870199	0,39513922	<,0001
12	452	0,0479	0,0777307	0,41220318	<,0001

Quadrado Médio da Correlação Canônica¹

De acordo com Freire (2004) as faixas do azul e do vermelho são as características "chave" para detectar fatores que possam afetar o desenvolvimento normal das plantas (devido à alta absorção dos cloroplastos), referindo-se em especial a deficiências de cálcio e fósforo, objeto de seu trabalho. Cita também que na faixa correspondente a cor verde, os cloroplastos têm a função de refletir.

Quanto a sensibilidade da região do infravermelho próximo à diferentes níveis de P, Mahajan et al. (2017) citaram as bandas 670, 1092, 1260 e 1460 nm (vermelho e infravermelho) como sendo comprimentos de onda sensíveis a P em seu trabalho. Al-Abbas et al. (1974) verificaram que a absorção a 830, 940 e 1100 nm foi menor nas folhas de milho com deficiência de P e Ca, indicando importância da região do infravermelho próximo na identificação da deficiência destes nutrientes, corroborando Osborne et al. (2004), que observaram na região NIR a maior correlação com a concentração de P na planta.

Ainda analisando a Tabela 5, o teste F demonstrou que as bandas selecionadas foram significativas a 10% de probabilidade de erro. Enquanto isso, os valores de Wilk's Lambda apontaram que os comprimentos de onda com menor habilidade de explicar os dados deste trabalho foram 608 e 696, com valores de 0,2134 e 0,2086, respectivamente, ainda assim, considerados valores satisfatórios.

Quanto ao quadrado médio da correlação canônica (QMCC) - que determina o quanto da variável dependente está sendo explicada pela variável independente, ou vice-versa – o fator de reflectância observado a partir da banda 608 representou 24,5% da variação nos dados na diferenciação entre tratamentos, enquanto a banda 452 representou 41,2% e as demais bandas valores intermediários entre estas duas, valores considerados relativamente baixos. Embora tenha ocorrido essa variação na representatividade das bandas, observou-se que todas as variáveis foram significativas ($p < 0,0001$).

Segundo Coleman et al. (1991), os baixos valores de QMCC obtidos utilizando fator de reflectância espectral são atribuídos as similaridades entre os tratamentos a partir dos quais os dados foram gerados. As doses de adubo fosfatado relativamente próximas podem ter promovido as similaridades de comportamento espectral na planta que levaram a baixos valores de QMCC.

Após selecionadas as 12 bandas que melhor caracterizaram os tratamentos deste trabalho, procedeu-se a realização da análise discriminante por meio do procedimento proc DISCRIM do software SAS. Os coeficientes que compõem as equações obtidas para os tratamentos estudados utilizando os dados de reflectância determinados pelo sensor Fieldspec, são apresentados na Tabela 6.

Tabela 6. Coeficientes dos modelos discriminantes lineares.

Variáveis	T1	T2	T3	T4	T5
Constante	-442,487	-441,681	-412,972	-403,249	-428,885
608	380211	234269	328463	287842	201723
696	12736	13283	13290	13738	15696
450	55838	71850	53089	61842	61059
781	1009277	919435	953736	913053	987978
742	-7300	-6315	-7391	-7123	-9226
782	-1001008	-912022	-945443	-905037	-978090
607	-279883	-186601	-223898	-200179	-121755
614	-160489	-94217	-192059	-153197	-154041
622	-180332	-273137	-172493	-170721	-200397
619	220727	299025	240481	215791	251836
665	9495	10051	8471	8797	9232
452	-58281	-74643	-55265	-63841	-63053

A partir dos coeficientes dos modelos discriminantes lineares, são geradas equações que permitem a classificação de indivíduos, em condições similares, aos diferentes grupos de tratamentos. Como exemplo, tomemos a equação do tratamento 1 (coluna T1 da Tabela 6). A equação discriminante para este tratamento será:

$$T1 = -442,487 - 380211 * (\text{reflectância da banda 608}) + 12736 * (\text{reflec. 696}) + 55838 * (\text{reflec. 450}) - 1009277 * (\text{reflec. 781}) - 7300 * (\text{reflec. 742}) - 1001008 * (\text{reflec. 782}) - 279883 * (\text{reflec. 607}) - 160489 * (\text{reflec. 614}) - 180332 * (\text{reflec. 622}) + 220727 * (\text{reflec. 619}) + 9495 * (\text{reflec. 665}) - 58281 * (\text{reflec. 452})$$

Consideremos que se tem em mãos os dados de reflectância referente as mesmas bandas utilizadas pela equação, de uma mesma cultura, que está sob condições de tratamentos semelhantes. Os dados de reflectância deverão ser aplicados em todas as equações da Tabela 6, que serão calculadas, e o tratamento (T1, T2, T3, T4 ou T5) que obtiver maior valor resultante da equação terá maior probabilidade de ser o tratamento referente ao indivíduo desconhecido em questão (NANNI, 2000).

O procedimento proc DISCRIM possui um critério de classificação que usa o quadrado da distância generalizada entre as classes, denominada distância generalizada de Mahalanobis. Esse critério de classificação é baseado em ambos, matriz de covariância individual dentro do grupo e matriz de covariância agrupada.

Cada observação é colocada na classe a partir da qual têm a menor distância generalizada entre os grupos, considerando as distâncias entre as médias das variáveis dependentes. Com isso, quanto maior for a distância entre os grupos (tratamentos), menor a probabilidade de ocorrer erros de classificação (COLEMAN e MONTEGOMERY, 1987). Os resultados deste procedimento são apresentados na Tabela 7.

Tabela 7. Quadrado da distância generalizada entre as médias.

Tratamento	T1	T2	T3	T4	T5
T1	0				
T2	7,16059	0			
T3	10,24678	16,53883	0		
T4	10,31366	14,53989	1,6279	0	
T5	18,23858	22,79153	4,6701	5,64748	0

Observa-se que os tratamentos T2 e T5 apresentaram a maior distância entre suas médias (22,79153), seguido pela distância entre os tratamentos T1 e T5 (18,23858), indicando que há diferença entre estes tratamentos em termos espectrais. Os demais tratamentos apresentam distâncias intermediariamente satisfatórias, indicando que existem diferenças, mas pode haver confusão entre eles, em especial entre os tratamentos T3 e T4, com distância de 1,6279.

Em seguida as equações obtidas foram testadas pelos próprios dados utilizados para elaborá-las. A Figura 14 resume a porcentagem de acertos na classificação dos tratamentos aqui examinados.

Os resultados da Figura 14 demonstram que os tratamentos T1 e T2 obtiveram maior porcentagem de acerto na classificação de seus dados, com 85% e 80% de acerto, respectivamente, sendo os mais discriminados dentre os tratamentos, assim como observado nas respostas espectrais da Figura 11 (Tópico 5.2), seguido por T3 e T5, ambos com 75% de assertividade, e o T4 com 60 %, indicando uma discriminação satisfatória, considerando as similaridades dos tratamentos.

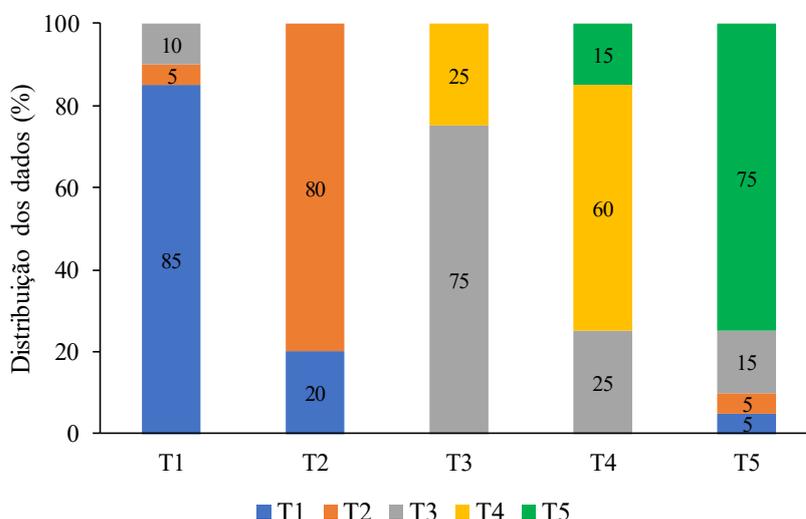


Figura 14. Análise discriminante linear do conjunto de dados referente ao adubo MAP. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 100% dos dados que compõem o modelo.

O erro médio do processo de classificação foi de 25% (Tabela 8), valor este relativamente alto, porém, considerando as características dos tratamentos, bem como interações do elemento com o solo, pode ser considerado satisfatório, visto que os maiores erros de classificação se encontram nos tratamentos em que as plantas receberam doses de adubo fosfatado, e não na testemunha, tendo estas doses diferenças de quantidade gradativas e não tão bruscas, além da competição solo-planta pelo elemento, que favorece a não absorção pela planta de todo adubo aplicado, promovendo diferenças proporcionalmente não tão bruscas no espectro, favorecendo a confusão.

Com o objetivo de reforçar a análise discriminante, foi realizada uma simulação no SAS, na qual 60% dos dados espectrais foram utilizados na geração de um modelo discriminante para cada tratamento, o qual foi testado pelos 40% restantes, assim, ao obter bons resultados com

equações providas de dados parciais, é de se esperar que o modelo com 100% dos dados seja de boa qualidade.

Tabela 8. Estimativa de erro para cada tratamento reclassificado pela análise discriminante.

Variáveis	T1	T2	T3	T4	T5	Total
Taxa ¹	0,15	0,2	0,25	0,4	0,25	0,25
Participação ²	0,2	0,2	0,2	0,2	0,2	1

¹Taxa de erro para cada classe; ²Probabilidade de participarem na própria classe.

Os dados foram selecionados de forma aleatória pelo software. O procedimento de simulação foi repetido 60 vezes, conforme programado no software, ou seja, o sistema escolheu aleatoriamente 60% dos dados para geração do modelo de discriminação e 40% para teste, por sessenta vezes consecutivas.

Na Figura 15 são apresentados os dados de porcentagem de acerto para classificação dos tratamentos a partir das equações discriminantes elaboradas utilizando 60% dos dados que compõem o modelo, os quais foram selecionados de forma aleatória.

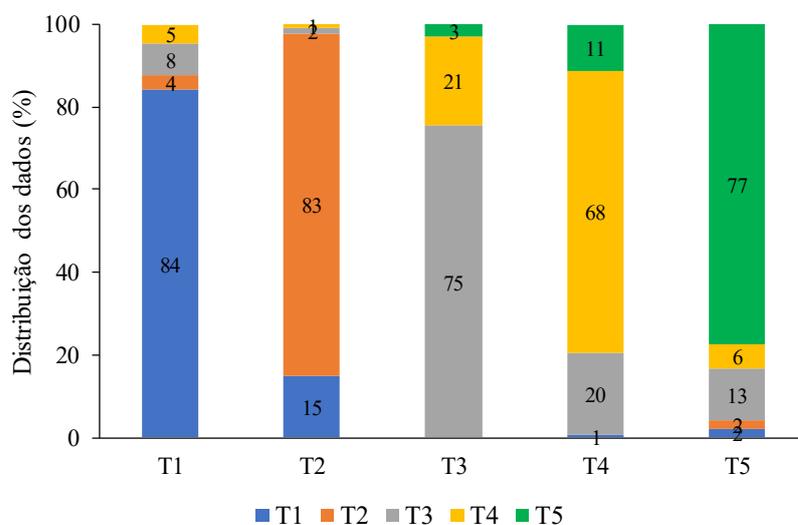


Figura 15. Análise discriminante linear do conjunto de dados referente ao adubo MAP. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 60% dos dados que compõem o modelo.

Observa-se que a testemunha (T1) e T2 seguem apresentando maior porcentagem de acerto na distribuição dos dados dentre os demais tratamentos, com 84% e 83% de acerto, respectivamente. Tal discriminação é esperada devido as diferenças visuais no espectro (Figura 11, Tópico 5.2) e das plantas na área experimental, visualmente debilitadas devido aos baixos níveis de adubação.

Enquanto isso, T3, T4 e T5 apresentaram 75%, 68% e 77% de acerto, respectivamente, apresentando confusão de seus dados entre estes mesmos tratamentos, em sua maioria, o que é esperado devido as características dos tratamentos. Além disso, estes valores são ainda satisfatórios considerando a aleatoriedade dos dados selecionados para compor a equação.

Na simulação, o modelo apresentado foi altamente significativo pelo teste Qui-quadrado ($p < 0,0001$), que verifica a frequência com que um dado observado de uma amostra se desvia significativamente ou não da frequência que se espera. A correlação entre os tratamentos, que indica o grau de associação entre os dados, apresentou r de 0,829, definido pelo coeficiente de contingência.

Após obtido o modelo discriminante a partir da simulação realizada com 60% dos dados de curvas espectrais, foram utilizados os 40% restantes para avaliar o desempenho do modelo. A porcentagem de acerto na distribuição dos dados dentre as classes é apresentada na Figura 16.

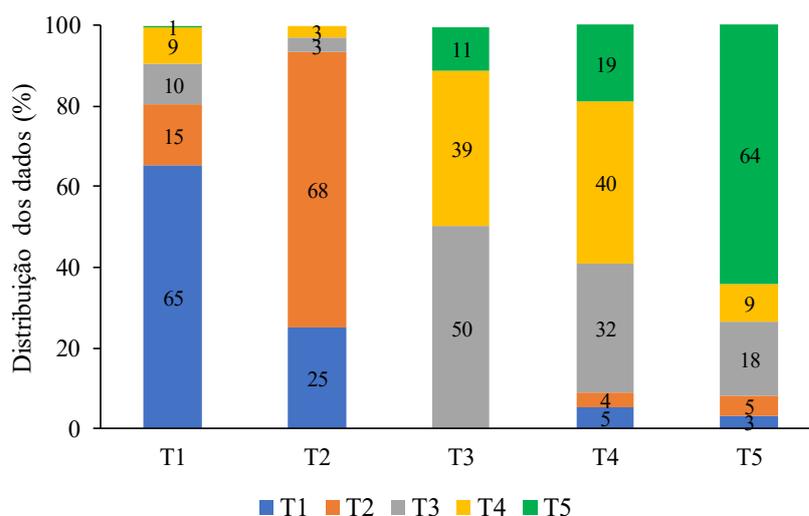


Figura 16. Análise discriminante linear do conjunto de dados referente ao adubo MAP. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 40% dos dados que compõem o modelo.

A partir da Figura 16, pôde-se observar que os tratamentos T1 e T2 (0 e 30 kg ha⁻¹ P₂O₅, respectivamente) mantiveram a tendência de maior porcentagem de acerto na discriminação dos dados dentre os demais tratamentos, com 65% e 68% de acerto, respectivamente. A maior porcentagem dos dados de T1 que apresentaram erro na distribuição, foram alocados para T2, que é o tratamento mais semelhante a testemunha devido a dose de adubação baixa, quando comparada a recomendação para suprir as necessidades da cultura, e vice-versa para T2, cuja maior parte dos dados confundidos foram alocados para T1.

O tratamento T5 (240 kg ha⁻¹ P₂O₅) também apresentou boa proporção de acerto no processo de discriminação, com 64% de acurácia. Este tratamento foi confundido principalmente com T3 e T4. Enquanto isso, T3 e T4 (60 e 120 kg ha⁻¹ P₂O₅) apresentaram 50% e 40% de acerto, sendo confundidos principalmente entre si. Nota-se então boa discriminação dos dados para os tratamentos das extremidades (maior e menor dose de adubação), enquanto os tratamentos intermediários apresentaram maior proporção de confusão.

Embora o acerto na distribuição dos dados tenha sido menor que nos modelos anteriores (testados com 100% e 60% dos dados), o que é esperado devido a aleatoriedade e menor quantidade de amostras, este ainda foi altamente significativo pelo teste Qui-quadrado (p<0,0001) e coeficiente de contingência r = 0,738.

Já para o experimento referente a fonte de adubo superfosfato simples, realizado a partir das mesmas técnicas e ferramentas do experimento anterior, foram selecionadas 6 bandas pelo procedimento proc STEPDISC do software SAS ao nível de significância de 10%, apresentadas na Tabela 9.

Tabela 9. Bandas selecionadas para participação na construção de modelos discriminantes lineares a partir de curvas espectrais de milho, obtidas pelo espectrorradiômetro em função de doses do adubo fosfatado SS.

Etapa	Entrada	Pr > F	Wilk's Lambda	Q.M. correlação ¹ canônica	Pr > QMCC
1	711	<,0001	0,4770774	0,13073065	<,0001
2	957	<,0001	0,3039611	0,18749189	<,0001
3	951	0,0465	0,2519698	0,21654428	<,0001
4	714	0,0193	0,2217381	0,2431752	<,0001
5	696	0,0927	0,2031446	0,25168077	<,0001
6	687	0,0915	0,1968191	0,25506069	<,0001

Quadrado Médio da correlação canônica¹.

As bandas selecionadas se encontram na região do vermelho e infravermelho próximo, indicando estas regiões como sensíveis na discriminação dos dados quando se trabalha com P. Estas informações corroboram com os dados de Osborne et al. (2002), os quais observaram que os comprimentos de onda de reflectância usados para prever a concentração de P estavam na região NIR do espectro (730 e 930 nm), em estágios iniciais de crescimento das plantas de milho (antes de V8). Jacob e Lawlor (1991) verificaram que o efeito inicial do estresse de P no milho, trigo e girassol foi decorrente do aumento no número de células menores por unidade de área foliar em comparação com a planta não estressada. Tal aumento do número de células sugeriria que a reflectância do NIR pode ser importante para prever o teor de P das plantas.

Essas informações confirmam também os dados do experimento anterior, o qual teve as principais bandas selecionadas na região do vermelho e infravermelho próximo, inclusive ambos os experimentos tiveram a banda 696 selecionadas em comum.

Ainda analisando a Tabela 9, o teste F demonstrou que as bandas foram significativas a 10% de probabilidade de erro. Os valores de Wilk's Lambda indicaram melhor separabilidade espectral para as bandas 696 e 687 (0,203 e 0,196, respectivamente), valores considerados satisfatórios. O QMCC variou entre 13% e 25%, sendo valores relativamente baixos, contudo, esperados devido as características dos tratamentos e da fonte de adubo.

O fertilizante superfosfato simples possui aproximadamente 16% de solubilidade em água, liberando, assim, o nutriente de forma gradual, permitindo que a cultura o receba em pequenas proporções, porém, por período prolongado, o que viabiliza boa disponibilidade e bom aproveitamento pelas plantas, ainda mais considerando as condições de pH e quantidade de argila características desta área experimental e, portanto, interação do elemento com o solo.

Esta característica do fertilizante permitiu que as plantas o aproveitassem melhor em todas as doses aplicadas, fato que foi confirmado pelo produto final do ciclo da cultura (produtividade, Tópico 5.6.1 deste trabalho), e que permitiu maior similaridade espectral dentre os tratamentos, o que foi observado na Figura 13 (comportamento espectral dos tratamentos, Tópico 5.2) e nesta análise discriminante, que demonstrou confusão relativamente grande na discriminação dentre os tratamentos. Além disso, segundo Novais e Smyth (1999) a maior ou menor competição entre planta e solo pelo P aplicado como fertilizante, faz com que a planta se ajuste para utilizar o teor de P que lhe é colocado à disposição.

Este fertilizante tem também como componentes secundários, o Ca (cálcio) e S (enxofre), elementos estes que participam do desempenho da fonte sobre a cultura. Segundo Pavan e Miyazama (1984) dentre as principais funções do cálcio na cultura do milho, se encontram a manutenção da membrana plasmática, absorção de íons, divisão celular, formação da parede celular, e processos metabólicos que ocorrem nas células. Enquanto o S é componente de proteínas, além de estar ligado às vitaminas biotina e tiamina, e também é componente do acetil-CoA, influenciando, portanto, todo o metabolismo de gorduras e carboidratos (BORGES, 2006).

Após selecionadas as bandas que melhor caracterizam os tratamentos deste trabalho, procedeu-se a realização da análise discriminante por meio do procedimento proc DISCRIM do software SAS. Os coeficientes que compõem as equações discriminantes lineares para este experimento são apresentados na Tabela 10.

Tabela 10. Coeficientes dos modelos discriminantes lineares.

Variáveis	T1	T2	T3	T4	T5
Constante	-858,76515	-891,17109	-875,58379	-893,38411	-850,19545
711	-51104	-64882	-67427	-62050	-63722
957	-6785	1270	2942	-1420	1213
951	9266	1027	-766,98145	3830	1003
714	44900	56539	58787	53970	55601
696	20050	24282	24917	23701	23667
687	-15155	-16979	-17214	-16791	-16562

A partir do relatório de quadrado da distância generalizada entre as médias, do procedimento proc DISCRIM (Tabela 11), pode-se observar que a testemunha (T1) apresentou boa distância dos demais tratamentos, indicando boa separabilidade, com valores entre 14,53 e 17,88. Já para os tratamentos T2, T3, T4 e T5, foram observadas distâncias pequenas entre as suas médias, variando entre 0,38 e 2,34, o que indica que haverá confusão entre tratamentos, conforme esperado e explicado anteriormente.

Tabela 11. Quadrado da distância generalizada entre as médias.

Tratamento	T1	T2	T3	T4	T5
T1	0				
T2	16,51977	0			
T3	16,10383	0,38028	0		
T4	17,88558	0,76956	1,92794	0	
T5	14,53169	1,15520	0,56978	2,34551	0

A Figura 17 resume a porcentagem de acertos na classificação dos tratamentos avaliados, calculados a partir das equações discriminantes elaboradas, utilizando os mesmos dados que participaram da composição das equações.

Os resultados da Figura 17 demonstraram boa assertividade do procedimento na classificação das amostras que representaram o tratamento testemunha (T1), com 85% de acerto na distribuição dos dados, seguido pelos tratamentos T5, T4 e T3, com 65%, 55%, 50% de acerto, respectivamente. O tratamento T2 demonstrou maior confusão na distribuição dos dados devido a variação nas suas curvas espectrais, provavelmente devido à baixa dose de adubação, ocasionando, muitas vezes, sobreposição com as curvas dos outros tratamentos, resultando em confusão na classificação.

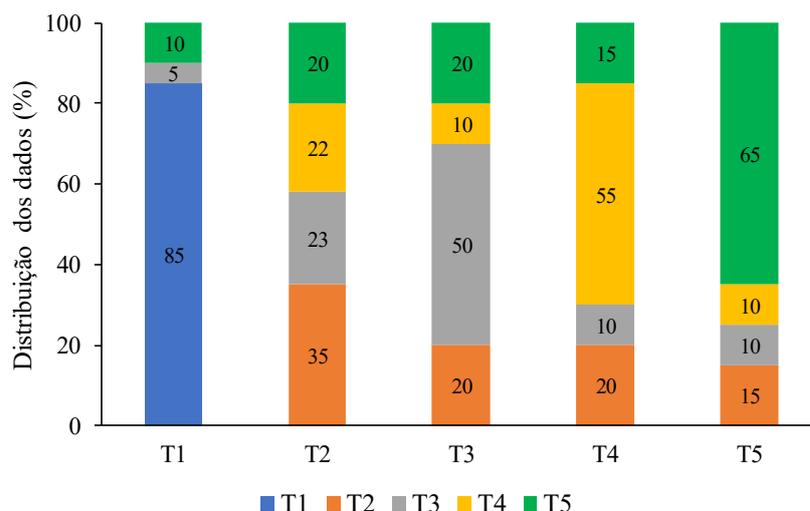


Figura 17. Análise discriminante linear do conjunto de dados referente ao adubo SS. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 100% dos dados que compõem o modelo.

As maiores porcentagens de erro foram observadas nos tratamentos que continham doses de adubo, enquanto o erro da testemunha se manteve baixo. O erro médio do processo de classificação foi de 39% (Tabela 12), valor relativamente alto e condizente às complexidades já citadas.

Tabela 12. Estimativa de erro para cada tratamento reclassificado pela análise discriminante.

Variáveis	T1	T2	T3	T4	T5	Total
Taxa ¹	0,15	0,50	0,50	0,45	0,35	0,39
Participação ²	0,2	0,2	0,2	0,2	0,2	1

¹Taxa de erro para cada classe; ²Probabilidade de participarem na própria classe.

Neste experimento também foi realizada a simulação na qual 60% dos dados espectrais foram utilizados na geração de um modelo discriminante para cada tratamento, o qual foi testado pelos 40% restantes. Na Figura 18 são apresentados os dados de porcentagem de acerto para classificação dos tratamentos a partir das equações discriminantes elaboradas, utilizando 60% dos dados que compõem o modelo, selecionados de forma aleatória.

Observa-se que a testemunha (T1) segue apresentando maior porcentagem de acerto na distribuição dos dados dentre os demais tratamentos, com 86% acurácia. Tal discriminação é esperada devido as diferenças visuais no espectro (Figura 13, Tópico 5.2) e das plantas na área experimental, visualmente debilitadas devido à ausência de adubação. Enquanto isso, T2, T3, T4 e T5 apresentaram 41%, 54%, 54% e 57% de acerto, respectivamente, apresentando confusão de seus dados entre eles mesmos, cujos tratamentos receberam adubação, e praticamente nenhuma confusão com o tratamento testemunha.

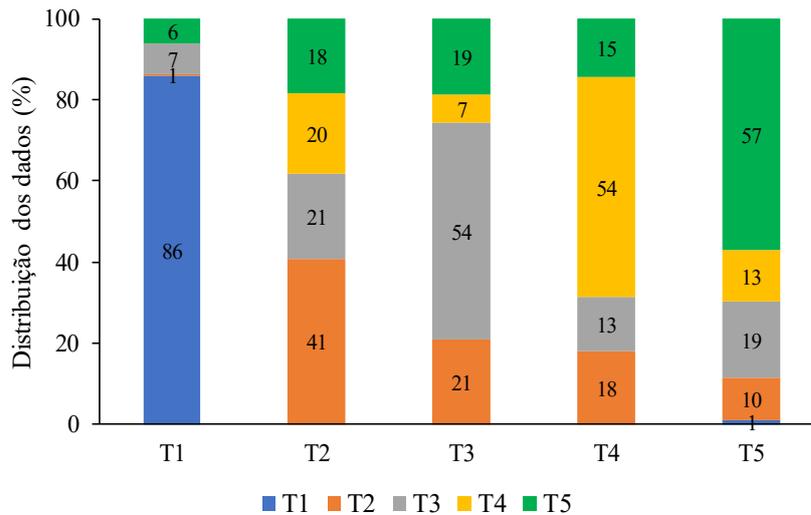


Figura 18. Análise discriminante linear do conjunto de dados referente ao adubo MAP. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 60% dos dados que compõem o modelo.

Na simulação, o modelo ajustado foi altamente significativo pelo teste Qui-quadrado ($p < 0,0001$) e a correlação entre os tratamentos apresentou r de 0,736, definido pelo coeficiente de contingência, considerado satisfatório.

Após obtido o modelo a partir da simulação com 60% dos dados de curvas espectrais, foram utilizados os 40% restantes para avaliar seu desempenho. A porcentagem de acerto na distribuição dos dados dentre as classes é apresentada na Figura 19.

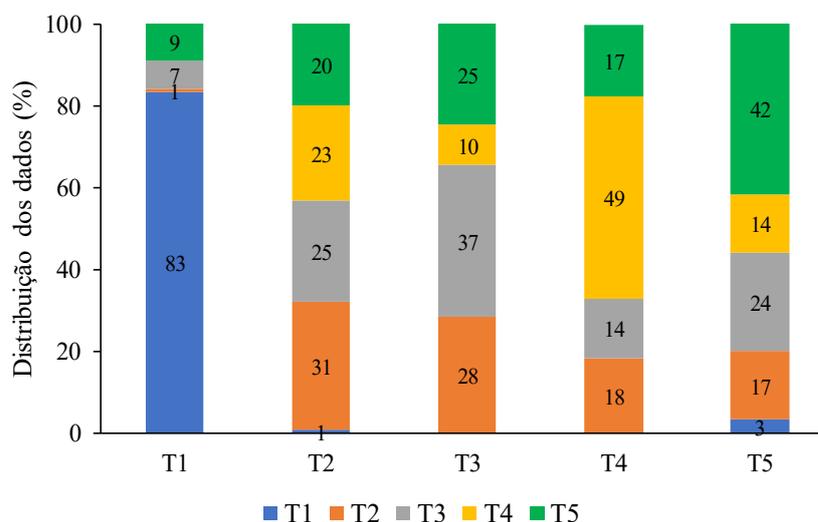


Figura 19. Análise discriminante linear do conjunto de dados referente ao adubo SS. Porcentagem de acerto na classificação espectral de cada tratamento (barra) em relação a todos os tratamentos (cores na barra), utilizando 40% dos dados que compõem o modelo.

Na Figura 19, pode-se observar que o modelo segue apresentando assertividade significativa (83%) na discriminação dos dados para o tratamento testemunha (T1), considerado

um bom resultado. Enquanto isso, os valores de acurácia na distribuição dos dados entre tratamentos com doses de adubação seguem apresentando confusão entre si (T2, T3, T4 e T5 com 31%, 37%, 49% e 42% de acerto, respectivamente), principalmente nas menores doses de adubação, e quase nenhuma confusão com a testemunha. O modelo foi altamente significativo pelo teste Qui-quadrado ($p < 0,0001$) e apresentou coeficiente de contingência $r = 0,689$.

Até então, há poucos trabalhos na literatura com os quais se possa comparar os dados encontrados neste estudo. Como exemplo, podemos citar Sibanda et al. (2015) trabalhando com diferentes combinações entre fertilizantes (combinações entre P, N e corretivos) em cultura de pastagem, citam que localizaram a partir de uma análise discriminante, os comprimentos de onda 731 e 737 na região do visível, como indicadores confiáveis da variação espectral a partir dos tratamentos estudados.

Estes autores citam também que os acertos na classificação espectral variaram entre 83% e 93%, no qual o tratamento contendo fósforo teve por volta de 80% de acerto na primeira fase de determinação do modelo e o tratamento testemunha foi distinguido com precisão de 85%, dados estes que se aproximam dos encontrados neste trabalho.

Autores têm dado preferência a trabalhar com análise discriminante linear em função de doses de adubação nitrogenada e potássica (Gómez-Casero et al., 2007; Furlanetto, 2018) visto que são elementos exigidos em maior quantidade pelas plantas em geral, as quais são, portanto, mais responsivas. A exigência do N é quase 6 vezes maior e do K quase 4 vezes, para cultura de milho, segundo SBCS/NEPAR (2017).

Com os resultados obtidos, pôde-se concluir que os modelos aqui elaborados promoveram a identificação de níveis nutricionais de fósforo em plantas de milho, contudo, é necessário apenas voltar mais atenção para as características do fertilizante utilizado e da área experimental, a fim de conhecer suas possíveis inferências aos tratamentos, as quais devem ser incluídas na análise no momento da interpretação dos dados.

5.4 Avaliação da relação entre índices de vegetação (IV's) e doses de adubo fosfatado

5.4.1 Índices de vegetação obtidos por espectrorradiômetro

Neste trabalho foram estudados os IV's NDVI, GNDVI, RNIR, GNIR, RVI e GRVI com o objetivo de avaliar seu desempenho na diferenciação dos tratamentos aqui utilizados. Para tanto, foram obtidos dados de reflectância das plantas dentre os diferentes tratamentos, os quais foram atestados pelos pressupostos de homocedasticidade das variâncias (Bartlett) e normalidade dos dados (Shapiro-wilk) (Apêndice A) e submetidos a análise de variância, que

resultou em diferença significativa entre os tratamentos ($p \leq 0,05$) para ambos os experimentos, na maioria das datas de avaliação. Em seguida procedeu-se o teste t para comparação das médias, ao nível de 5% de probabilidade de erro. A análise foi realizada para todos os períodos de avaliações (V6, V7, VT, R1, R2, R3, R4 e R5), contudo, apenas as datas que tiveram resultados significativos, entre tratamentos, tiveram seus dados apresentados.

Na Tabela 13 estão apresentados os resultados dos testes de média realizados para os períodos de avaliação correspondente aos estádios V6, V7, VT, R1, R2 e R3 (30, 37, 53, 66, 73 e 80 DAE, respectivamente), para o experimento composto pelo fertilizante MAP.

Para interpretação dos índices de vegetação NDVI, GNDVI, RVI e GRVI, deve-se saber que os maiores valores indicam melhor resposta destes IV's, enquanto para os índices RNIR e GNIR, os menores valores é que indicam melhor resposta dos IV's. Isso ocorre devido à disposição das bandas em suas equações.

Neste experimento é possível observar que os estádios V6, VT, e R3 apresentaram o mesmo comportamento, no qual os tratamentos T1 e T2 (0 e 30 kg ha⁻¹ P₂O₅) não apresentaram diferenças significantes entre si, contudo, diferiram significativamente dos demais tratamentos (T3, T4 e T5, com 60, 120 e 240 kg ha⁻¹ P₂O₅, respectivamente). Esse resultado demonstra que os IV's analisados a partir de teste de médias foram sensíveis na diferenciação de tratamentos debilitados (testemunha e menor dose de adubação) em relação aos tratamentos cujas plantas se encontravam melhor nutridas por fósforo, devido as diferenças nas respostas espectrais influenciadas pelos tratamentos. Contudo, não demonstraram habilidade em diferenciar plantas com respostas espectrais relativamente próximas, que é o caso dos tratamentos T3, T4 e T5, conforme observado nas curvas do espectro de reflectância (Figura 11, Tópico 5.2).

O estádio V7 demonstrou ambiguidade estatística entre alguns tratamentos, ainda assim, as diferenças significativas mantiveram a tendência dos estádios citados anteriormente. Em R1 e R2 apenas o índice GRVI (combinação das bandas infravermelho próximo e verde) se desviou do comportamento dos estádios já citados, apresentando-se como um índice sensível na diferenciação dos tratamentos nestas fases. Este índice demonstrou habilidade significativa para diferenciar T5 dos demais tratamentos nestes estádios, bem como T4 e T3 também foram diferenciados de T2 e T1. O que é de se esperar visto que este índice utiliza a banda NIR como objeto principal, banda esta que apresenta alterações na reflectância de acordo com a estrutura foliar, que pode ser influenciada pelos níveis de nutrição por fósforo.

Jacob e Lawlor (1991) verificaram que o efeito inicial do estresse de P no milho, trigo e girassol foi aumento no número de células menores por unidade de área foliar em comparação

com a planta não estressada, e que tal aumento do número de células sugere importância da refletância na banda NIR para prever o teor de P das plantas. Al-Abbas et al. (1974) verificaram alterações na absorção da REM na banda NIR em plantas de milho de acordo com deficiência de P e Ca, indicando importância da região do infravermelho próximo na identificação da deficiência destes nutrientes, corroborando com Osborne et al. (2004), que observaram na região NIR a maior correlação com a concentração de P na planta.

Tabela 13. Teste de comparação de médias dos IV's obtidos por meio do espectrorradiômetro em diferentes datas de avaliação, para o experimento com adubo fosfatado MAP.

Estádio	Tratamento	NDVI	GNDVI	RNIR	GNIR	RVI	GRVI
V6	1	0,5855 b*	0,5330 b	0,2615 b	0,3048 b	3,8299 b	3,2915 b
	2	0,5828 b	0,5447 b	0,2642 b	0,2955 b	3,8322 b	3,4244 b
	3	0,6483 a	0,6226 a	0,2134 a	0,2326 a	4,6992 a	4,3109 a
	4	0,6380 a	0,6101 a	0,2210 a	0,2422 a	4,5358 a	4,1402 a
	5	0,6558 a	0,6288 a	0,2081 a	0,2283 a	4,8354 a	4,4215 a
	CV (%)	4,07	5,12	8,36	9,35	7,94	8,81
V7	1	0,6229 bc	0,5759 bc	0,2324 bc	0,2692 b	4,3146 bc	3,7232 bc
	2	0,6072 c	0,5539 c	0,2446 c	0,2872 b	4,1080 c	3,4945 c
	3	0,6719 a	0,6334 a	0,1963 a	0,2246 a	5,1162 a	4,4754 a
	4	0,6545 ab	0,6166 ab	0,2088 ab	0,2371 a	4,7947 ab	4,2230 ab
	5	0,6796 a	0,6453 a	0,1912 a	0,2164 a	5,3209 a	4,7176 a
	CV (%)	3,80	4,41	8,50	8,37	8,59	8,89
VT	1	0,6165 b	0,5766 b	0,2372 b	0,2686 b	4,2214 b	3,7318 b
	2	0,6111 b	0,5704 b	0,2416 b	0,2739 b	4,1659 b	3,6731 b
	3	0,6809 a	0,6570 a	0,1899 a	0,2071 a	5,2854 a	4,8488 a
	4	0,6884 a	0,6644 a	0,1846 a	0,2019 a	5,4529 a	5,0027 a
	5	0,7084 a	0,6869 a	0,1707 a	0,1856 a	5,8728 a	5,4006 a
	CV (%)	3,54	4,14	8,45	8,85	7,94	8,37
R1	1	0,6028 b	0,5513 b	0,2481 b	0,2898 b	4,0622 b	3,4913 c
	2	0,6026 b	0,5424 b	0,2483 b	0,2973 b	4,0583 b	3,3961 c
	3	0,6687 a	0,6335 a	0,1987 a	0,2244 a	5,0671 a	4,4707 b
	4	0,6898 a	0,6584 a	0,1836 a	0,2060 a	5,4644 a	4,8673 ab
	5	0,6912 a	0,6662 a	0,1827 a	0,2003 a	5,4945 a	5,0033 a
	CV (%)	3,00	3,92	6,92	7,98	6,44	6,63
R2	1	0,5996 b	0,5637 b	0,2506 b	0,2794 b	4,0222 b	3,6057 c
	2	0,5978 b	0,5602 b	0,2520 b	0,2823 b	3,9962 b	3,5725 c
	3	0,6546 a	0,6327 a	0,2091 a	0,2253 a	4,8351 a	4,4793 b
	4	0,6710 a	0,6479 a	0,1970 a	0,2138 a	5,1055 a	4,6976 ab
	5	0,6757 a	0,6553 a	0,1935 a	0,2083 a	5,1826 a	4,8162 a
	CV (%)	2,49	2,72	5,50	5,57	5,35	4,98
R3	1	0,6047 b	0,5565 b	0,2466 b	0,2857 b	4,0861 b	3,5450 b
	2	0,5911 b	0,5370 b	0,2572 b	0,3015 b	3,9089 b	3,3348 b
	3	0,6490 a	0,6174 a	0,2128 a	0,2366 a	4,7076 a	4,2384 a
	4	0,6497 a	0,6146 a	0,2123 a	0,2387 a	4,7116 a	4,1932 a
	5	0,6500 a	0,6201 a	0,2121 a	0,2346 a	4,7268 a	4,2795 a
	CV (%)	3,27	4,03	6,89	7,42	6,52	6,87

*Médias seguidas pela mesma letra na coluna não diferem estatisticamente entre si pelo teste t a 5% de probabilidade de erro.

No estágio R4 e R5 não foram observadas diferenças significativas entre tratamentos, inclusive a testemunha. A senescência gradual das folhas provavelmente ocasionou semelhança entre a reflectância dos tratamentos. Os menores coeficientes de variação (CV) foram observados para os índices de vegetação NDVI e GNDVI, com média de 3,36 e 4,05, respectivamente, seguidos por RVI e GRVI, com CV médio de 7,13 e 7,42 e RNIR e GNIR, com 7,43 e 7,92, respectivamente, sendo estes CVs considerados satisfatórios para que a análise seja confiável.

A faixa de valores de reflectância obtidas para o índice NDVI variaram de 0,58-0,69. GNDVI teve seus valores entre 0,53-0,66, enquanto RVI e GRVI tiveram seus valores entre 3,82-5,50 e 3,29-5,05, respectivamente. Para RNIR e GNIR, os valores de reflectância observados foram de 0,26-0,18 e 0,30-0,20, respectivamente. Furlanetto (2018) trabalhando com doses de potássio em milho, observou os valores máximos dos IV's GRVI, NDVI, GNDVI, GNIR, RNIR e RVI de 4,8, 0,81, 0,65, 0,20, 0,09, 0,9, respectivamente, valores estes semelhantes aos observados neste trabalho. Os valores de reflectância e seus produtos, neste caso os IV's, podem alterar para maior ou menor de acordo com a cultura, nutrição, umidade e até mesmo condições ambientais, assim, o objetivo principal deve ser analisar as variações de cada índice dentro das próprias condições de trabalho.

Todos os índices de vegetação demonstraram valores crescentes dentre os estádios vegetativos, com seus valores máximos observados em VT, seguido por diminuição gradual dos valores de reflectância, o que é de se esperar visto que neste estágio a planta atinge o máximo desenvolvimento e crescimento (MAGALHÃES e DURÃES, 2006).

Em seguida são apresentados, na Tabela 14, os resultados dos testes de média realizados para os períodos de avaliação correspondente aos estádios V6, V7, VT, R1 e R2 (30, 37, 53, 66 e 73 DAE, respectivamente), para o experimento composto pelo fertilizante superfosfato simples.

Para este experimento, os estádios V6, V7, VT, R1 e R2 apresentaram o mesmo comportamento em todos os IV's, no qual apenas o tratamento testemunha (T1) diferiu significativamente dos demais tratamentos (T2, T3, T4 e T5). A ausência de diferença significativa entre os tratamentos compostos por doses de adubo ocorreu devido à semelhança na reflectância espectral das plantas, conforme observado na Figura 13 (comportamento espectral dos tratamentos, Tópico 5.2), provavelmente como resultado do bom aproveitamento da cultura sobre todas as doses de fertilizante aplicadas, fato este confirmado pelo produto final do ciclo da cultura (produtividade, Tópico 5.6.1 deste trabalho). O fertilizante superfosfato

simples possui aproximadamente 16% de solubilidade, assim, libera o nutriente de forma gradual, permitindo que a cultura o receba em pequenas proporções e por período prolongado, viabilizando boa disponibilidade e bom aproveitamento pelas plantas, além dos componentes secundários Ca e S, que auxiliam no desempenho da fonte sobre a cultura. Assim, observa-se aptidão dos IV's em diferenciar o tratamento com plantas debilitadas de tratamentos com plantas relativamente nutridas.

Tabela 14. Teste de comparação de médias dos IV's obtidos por meio do espectrorradiômetro em diferentes datas de avaliação, para o experimento com adubo fosfatado SS.

Estádio	Tratamento	NDVI	GNDVI	RNIR	GNIR	RVI	GRVI
V6	1	0,5855 b	0,5330 b	0,2615 b	0,3048 b	3,8299 b	3,2915 b
	2	0,6477 a*	0,6208 a	0,2139 a	0,2341 a	4,6915 a	4,2944 a
	3	0,6453 a	0,6186 a	0,2156 a	0,2357 a	4,6461 a	4,2535 a
	4	0,6563 a	0,6299 a	0,2074 a	0,2270 a	4,8259 a	4,4129 a
	5	0,6518 a	0,6249 a	0,2108 a	0,2309 a	4,7507 a	4,3452 a
	CV (%)	1,85	2,55	3,96	4,95	4,05	4,85
V7	1	0,6229 b	0,5759 b	0,2324 b	0,2692 b	4,3146 b	3,7232 b
	2	0,6772 a	0,6388 a	0,1929 a	0,2210 a	5,2676 a	4,6028 a
	3	0,6605 a	0,6200 a	0,2047 a	0,2350 a	4,9298 ab	4,3042 a
	4	0,6722 a	0,6346 a	0,1961 a	0,2236 a	5,1270 a	4,4901 a
	5	0,6694 a	0,6306 a	0,1982 a	0,2268 a	5,0895 a	4,4477 a
	CV (%)	3,41	3,93	7,98	7,89	8,12	8,06
VT	1	0,6165 b	0,5766 b	0,2372 b	0,2686 b	4,2214 b	3,7318 b
	2	0,6821 a	0,6563 a	0,1889 a	0,2076 a	5,3038 a	4,8413 a
	3	0,6904 a	0,6636 a	0,1832 a	0,2022 a	5,4743 a	4,9570 a
	4	0,6939 a	0,6693 a	0,1807 a	0,1981 a	5,5461 a	5,0584 a
	5	0,6924 a	0,6687 a	0,1817 a	0,1985 a	5,5070 a	5,0407 a
	CV (%)	2,20	2,79	5,46	6,25	5,57	6,18
R1	1	0,6028 b	0,5513 b	0,2481 b	0,2898 b	4,0622 b	3,4913 b
	2	0,6613 a	0,6282 a	0,2042 a	0,2290 a	4,9474 a	4,4336 a
	3	0,6712 a	0,6333 a	0,1968 a	0,2246 a	5,1025 a	4,4694 a
	4	0,6796 a	0,6410 a	0,1908 a	0,2189 a	5,2540 a	4,5915 a
	5	0,6675 a	0,6347 a	0,1994 a	0,2234 a	5,0181 a	4,4793 a
	CV (%)	3,54	4,91	8,31	9,98	7,66	9,25
R2	1	0,5996 b	0,5637 b	0,2506 b	0,2794 b	4,0222 a	3,6057 b
	2	0,6609 a	0,6376 a	0,2042 a	0,2212 a	4,9039 a	4,5209 a
	3	0,6413 a	0,6151 a	0,2185 a	0,2383 ab	4,5867 a	4,2011 ab
	4	0,6566 a	0,6292 a	0,2078 a	0,2284 a	4,9011 a	4,4702 a
	5	0,6472 a	0,6227 a	0,2142 a	0,2326 a	4,6842 a	4,3156 a
	CV (%)	4,10	4,67	8,95	9,24	9,04	9,38

*Médias seguidas pela mesma letra na coluna não diferem estatisticamente entre si pelo teste t a 5% de probabilidade de erro.

Enquanto isso, os estádios R3, R4 e R5 não apresentaram resultados significativos entre tratamentos, dados estes também observados visualmente na análise espectral dos tratamentos (Figura 13). Os menores coeficientes de variação foram observados para os índices de vegetação NDVI e GNDVI, com média de 3,03 e 3,80, respectivamente, seguidos por RVI e

RNIR, com CV médio de 6,77 e 6,81 e GRVI e GNIR, com 7,39 e 7,54, respectivamente, sendo estes CVs considerados satisfatórios para validação da análise.

Quanto a faixa de valores de reflectância obtidas, para o índice NDVI variaram de 0,58-0,69. GNDVI teve seus valores entre 0,53-0,66, enquanto RVI e GRVI tiveram seus valores entre 3,82-5,54 e 3,29-5,05, respectivamente. Para RNIR e GNIR, os valores de reflectância observados foram de 0,26-0,18 e 0,30-0,19, respectivamente, valores estes extremamente próximos aos encontrados no experimento anterior, o que confirma que são inerentes a cultura em função de níveis nutricionais de adubo fosfatado. Todos os índices de vegetação demonstraram seu valor máximo no estágio VT.

Diversos autores tem buscado correlacionar índices de vegetação a atributos biofísicos de culturas (FURLANETTO, 2018; LOOZEN et al., 2019; PIMSTEIN et al., 2011;). Li et al. (2018), trabalhando com doses de P em lichia, verificou que os IV's correspondentes às bandas 685, 870, e P1085 (vermelho e infravermelho próximo) foram fortemente correlacionados com o teor foliar de P, e que na faixa de 715 a 1350nm, a curva de correlação teve uma tendência crescente. Gracia-Romero et al. (2017), trabalhando com doses de P em milho, citam que bandas espectrais em torno de 570, 670 e 700 nm, correlacionam-se com o teor de P no baixo nível de fertilização.

Os índices de vegetação fornecem um método simples para quantificar a atividade vegetativa da planta a partir de espectros de folhas ou dossel, e podem servir de base para muitas aplicações de sensoriamento remoto no manejo das culturas, porque estão bem correlacionados com a biomassa verde e o índice de área foliar dos dosséis das culturas (PINTER JR et al., 2003).

Os IV's obtidos por dados espectrais demonstram aptidão para distinguir tratamentos com severa deficiência nutricional de tratamentos cujas planta encontram-se bem nutridas, enquanto tratamentos com nutrição intermediária não foram diferenciados dos tratamentos com maiores doses de adubação. Este fato demonstra aptidão dos IV's no monitoramento agrícola, contudo, necessidade de mais estudos e refinamento da técnica, para identificação de plantas em condição de fome oculta.

5.4.2 Índices de vegetação obtidos por câmeras digitais

Após obtidos os valores de DN das imagens referente a cada parcela experimental e convertidos para reflectância (Tópico 4.3.2), foram calculados os IV's NDVI, GNDVI, RNIR, GNIR, RVI e GRVI com o objetivo de avaliar seu desempenho na diferenciação dos

tratamentos. Foram utilizados apenas os dados referentes aos tratamentos T2, T3, T4 e T5, excluindo-se desta análise o tratamento testemunha devido a pequena representatividade das plantas nas imagens (plantas altamente debilitadas devido à ausência de adubo fosfatado) e alta predominância do solo, o que pode influenciar nos dados espectrais.

Os dados de reflectância das plantas dentre os diferentes tratamentos, foram atestados pelos pressupostos de homocedasticidade das variâncias (Bartlett) e normalidade dos dados (Shapiro-wilk) (Apêndice B) e submetidos a análise de variância, que resultou em diferença significativa entre os tratamentos ($p \leq 0,05$) para o experimento com fertilizante MAP, na maioria das datas avaliadas. Em seguida procedeu-se o teste t para comparação das médias, ao nível de 5% de probabilidade de erro. A análise foi realizada para os períodos de avaliações VT, R1, R2, R3 e R4, contudo, foram ilustradas apenas as datas que tiveram resultados significativos entre tratamentos (Tabela 15).

Tabela 15. Teste de comparação de médias dos IV's obtidos por meio de imagens aéreas em diferentes datas de avaliação, para o experimento com adubo fosfatado MAP.

Estádio	Tratamentos	NDVI	GNDVI	RVI	GNIR	RNIR	GRVI
VT	2	0,5922 b*	0,6447 b	3,9238 c	0,2159 b	0,2564 b	4,6299 b
	3	0,8567 a	0,8408 a	13,0346 b	0,0864 a	0,0771 a	11,6146 a
	4	0,8543 a	0,8432 a	12,7848 b	0,0850 a	0,0785 a	11,7570 a
	5	0,8735 a	0,8578 a	14,9282 a	0,0765 a	0,0675 a	13,2157 a
	CV (%)	1,49	1,19	6,13	4,82	8,45	8,73
R1	2	0,7132 c	0,7050 c	6,0360 c	0,1734 b	0,1675 c	5,8719 c
	3	0,8021 ab	0,7642 ab	9,1401 b	0,1336 a	0,1098 ab	7,5145 ab
	4	0,7806 b	0,7402 bc	8,2344 b	0,1495 ab	0,1234 b	6,7828 bc
	5	0,8239 a	0,7839 a	10,4150 a	0,1212 a	0,0966 a	8,3294 a
	CV (%)	1,84	2,82	6,29	9,86	7,66	8,65
R2	2	0,6441 b	0,6526 b	4,7015 b	0,2110 b	0,2172 b	4,8408 b
	3	0,7714 a	0,7471 a	7,8208 a	0,1448 a	0,1291 a	6,9544 a
	4	0,7748 a	0,7485 a	7,9027 a	0,1438 a	0,1268 a	6,9948 a
	5	0,7910 a	0,7631 a	8,7385 a	0,1346 a	0,1169 a	7,5980 a
	CV (%)	4,14	4,96	12,19	16,02	14,91	13,93
R3	2	0,5509 b	0,6018 b	3,6020 b	0,2529 a	0,2935 b	4,2787 b
	3	0,7243 a	0,7229 ab	6,3016 ab	0,1609 a	0,1600 a	6,2406 ab
	4	0,7245 a	0,7169 ab	6,3608 ab	0,1653 a	0,1601 a	6,1683 ab
	5	0,7578 a	0,7464 a	7,6018 a	0,1457 a	0,1385 a	7,0800 a
	CV (%)	10,34	10,28	23,48	30,59	30,20	21,12

*Médias seguidas pela mesma letra na coluna não diferem estatisticamente entre si pelo teste t a 5% de probabilidade de erro.

A partir da Tabela 15 pôde-se observar que em VT apenas o índice RVI apresentou resultado significativo gradual entre tratamentos, com T2 diferindo significativamente de T3 e T4, que também diferiram de T5. Os demais índices dos estádios VT e R2 apresentaram apenas T2 ($30 \text{ kg ha}^{-1} \text{ P}_2\text{O}_5$) diferindo significativamente dos demais tratamentos (T3, T4 e T5, com 60, 120 e $240 \text{ kg ha}^{-1} \text{ P}_2\text{O}_5$, respectivamente).

No estágio R1, somente GNIR demonstrou o comportamento no qual T2 é o único tratamento que difere significativamente dos demais. Os outros índices demonstraram T2 e T5 diferindo significativamente entre si e de todos os demais tratamentos, enquanto T3 e T4 oscilavam entre diferença significativa e ambiguidade estatística entre os tratamentos. Este foi o estágio mais oportuno para diferenciação estatística entre tratamentos, a partir de IV's obtidos por imagens aéreas. Ainda nesta fase, o RVI separou os tratamentos da forma citada e sem ambiguidade, demonstrando-se como o melhor IV para esta situação. Este fato era esperado, visto que este IV utiliza a banda NIR como objeto principal, banda esta que apresenta alterações na reflectância de acordo com a estrutura foliar, que pode ser influenciada pelos níveis de nutrição por fósforo, como já citado. Li et al. (2018) trabalhando com doses de P em lichia, observaram boa correlação entre NDVI e RVI e os tratamentos, principalmente no estágio de florescimento da cultura. Mahajan et al. (2017) citaram a região no NIR como sendo comprimentos de onda sensíveis a P em seu trabalho.

Enquanto isso, no estágio R3 os IV's apresentaram apenas T2 diferindo significativamente dos demais tratamentos. Para GNIR foi observada ausência de diferença significativa entre tratamentos. Provavelmente esse índice foi mais sensível a heterogeneidade entre os dados que ocorreu devido a fase em que se encontrava o dossel da cultura.

Nos estádios VT e R1, os menores coeficientes de variação foram observados para os índices de vegetação NDVI e GNDVI, com média de 1,66 e 2,0, respectivamente, seguidos por RVI e GNIR, com CV médio de 6,21 e 7,34 e RNIR e GRVI, com 8,05 e 8,69, respectivamente, sendo estes CVs considerados satisfatórios para validação da análise. A partir de R2, apesar dos dados terem sido aprovados pelos pressupostos de ANOVA, os CVs observados apresentaram valores muito altos, aproximadamente o dobro dos observados nos estádios anteriores, o que indica heterogeneidade dos dados e ocasiona diminuição da precisão da análise, sendo esta considerada não válida nestes estádios.

Para os estádios estudados neste tópico, a faixa de valores de reflectância para NDVI varia de 0,55-0,87, GNDVI teve seus valores entre 0,60-0,85, enquanto RVI e GRVI tiveram seus valores entre 3,6-14,9 e 4,2-13,2, respectivamente. Para RNIR e GNIR os valores de reflectância observados foram entre 0,29-0,06 e 0,25-0,07, respectivamente. Todos os índices de vegetação demonstraram valores máximos também em VT, assim como observado nos IV's obtidos pelo espectrorradiômetro. Estes valores de índice de vegetação observados foram mais altos que os obtidos pelo espectrorradiômetro. A maior complexidade de dados obtidos de todo o dossel da cultura pela imagem em relação aos dados pontuais de uma pequena área da folha

obtida pelo espectrorradiômetro, além da diferença das fontes de iluminação (iluminação do sol para as imagens e luz do próprio sensor para o espectrorradiômetro) provavelmente promovem tais diferenças, visto que os dados foram coletados no mesmo dia pelos dois sensores.

Gracia-Romero et al. (2017) estudando índices de vegetação a partir de dados de imagens e coletados por espectrorradiômetro, observaram que os IV's obtidos pelos dados do sensor portátil a nível de campo também apresentaram menores valores, em comparação com os mesmos índices avaliados pela câmera multiespectral acoplada na plataforma aérea, corroborando com este trabalho.

Analisando os resultados de teste de médias para o estádio R1 de ambos os sensores, é possível notar que os dados obtidos das imagens demonstraram maior sensibilidade na diferenciação de níveis nutricionais, resultando em diferença significativa dos tratamentos T2 e T5 entre si e dos demais tratamentos na maioria dos IV's. Enquanto isso, os resultados obtidos pelo espectrorradiômetro, demonstraram sensibilidade para separar apenas T2 dos demais tratamentos. Nenhum dos índices em ambos os sensores demonstraram sensibilidade suficiente para diferenciar os tratamentos intermediários T3 e T4.

Furlanetto (2018) comparando os sensores espectrorradiômetro e imagens obtidas por câmeras digitais também observou que este segundo sensor apresentou maior capacidade na diferenciação de tratamentos, contudo, também não foi capaz de diferenciar tratamentos com doses de nutrientes intermediários, o qual denominou de fome oculta.

A diferença na estrutura e operacionalização de ambos os sensores promove diferença na coleta de dados, na qual o espectrorradiômetro coleta informações de amostras representativas da parcela (pequenas porções de folhas), enquanto as imagens possuem maior abrangência amostral, visto que contemplam toda área útil da parcela. Provavelmente este fato é o que influencia nos valores de IV's obtidos por cada sensor.

Segundo Pinter Jr et al. (2003) mesmo quando as propriedades espectrais da folha permanecem relativamente constantes durante toda a estação, os espectros do dossel mudam dinamicamente à medida que as proporções do solo e da vegetação mudam e o arranjo arquitetural dos componentes da planta varia. Assim, não é de se surpreender que as assinaturas espectrais das copas das plantações sejam mais complexas e frequentemente bastante diferentes das obtidas de folhas verdes isoladas, medidas sob condições de iluminação controladas.

Para o experimento referente ao fertilizante SS, os dados de reflectância das plantas dentre os diferentes tratamentos (T2, T3, T4 e T5) também foram atestados pelos pressupostos de homocedasticidade das variâncias (Bartlett) e normalidade dos dados (Shapiro-wilk)

(Apêndice B) e submetidos a análise de variância, contudo, resultaram em diferença não significativa entre os tratamentos em todas as datas avaliadas, sendo assim, os dados não foram apresentados.

Com a retirada do tratamento testemunha desta análise devido a possível contaminação dos dados pela predominância de solo na imagem, restaram apenas os tratamentos compostos por doses de adubação. Conforme visualizado na Figura 13 (Tópico 5.2) os valores de reflectância destes tratamentos são muito similares, a ponto de quase não se notar diferenças visuais, provavelmente devido a característica de solubilidade do fertilizante que leva a gradual e prolongada disponibilidade dos nutrientes no solo e, portanto, melhor aproveitamento destes pelas plantas, conforme já citado nos tópicos anteriores. Assim, os IV's não foram sensíveis o suficiente para diferenciar estes tratamentos.

Gasparotto (2014) trabalhando com adubação nitrogenada em milho, observou que os dados obtidos com câmera digital também foram pouco sensíveis na distinção de tratamentos. Furlanetto (2018) concluiu que os IV's obtidos a partir de dados de câmeras digitais não tiveram sensibilidade suficiente para diferenciar tratamentos com doses similares de adubação potássica. Varella et al. (2019) encontrou diferenças significativas entre tratamentos contendo adubação nitrogenada, contudo, considerou baixos seus valores de R^2 ($\cong 0,60$). Já Sakamoto et al. (2012), concluíram que os índices de vegetação baseados em imagens de câmeras digitais têm a possibilidade de estimar uma ampla variedade de parâmetros biofísicos em culturas.

5.5 Modelo de predição para fósforo foliar utilizando Partial Least Square Regression (PLSR) a partir de dados obtidos pelo espectrorradiômetro

Regressão por Quadrados Mínimos Parciais é um método de regressão multivariada que modela as variáveis dependentes e independentes simultaneamente, com objetivo de obter modelos preditivos para as variáveis dependentes. Segundo Tobias (1995) a ideia geral do método é extrair fatores latentes das variáveis independentes que melhor preverão os valores das variáveis dependentes.

A partir do conjunto de dados composto por bandas espectrais (variáveis independentes) e valor de teor de fósforo foliar (variáveis dependentes) para cada parcela, foi elaborado um modelo de estimativa de P foliar em plantas de milho em função das respostas espectrais da planta, utilizando o método PLSR. Considerando a finalidade do processo, neste momento, as duas fontes de adubo fosfatado serão consideradas um mesmo conjunto de dados, totalizando 36 amostras (parcelas).

Foram selecionadas aleatoriamente 28 amostras para construção do modelo e 8 amostras para testar a predição deste. A distribuição dos dados foi avaliada pelas ferramentas Hotelling's T^2 (a 5% de probabilidade de erro) e Leverage, os quais identificaram ausência de "outliers", assim, todas as amostras participaram da construção do modelo.

Barmeier et al. (2017) utilizaram 30 amostras para predição de N em folhas de cevada, enquanto Pullanagari et al. (2016) utilizaram 56 amostras para estimativa de P foliar em pastagem. Furlanetto (2018) utilizou 27 amostras para calibração e 9 para validação de dados de N foliar em milho. Não existe uma regra única quanto a quantidade de amostras a se utilizar, a qualidade e representatividade das amostras e bom senso na escolha do tamanho amostral e número de variáveis é preferível (MINGOTI, 2005). Contudo, Hair Jr et al. (2009) citam que um tamanho amostral mínimo em análise multivariada deve conter pelo menos 20 amostras por grupo.

O número de fatores necessários para explicar a maior parte da variação entre as variáveis em estudo e, com menor valor de RMSE, foram 5 fatores. Segundo Tobias (1995) a ideia geral da PLSR é tentar extrair fatores latentes que respondam o máximo possível na variação dos dados. Um alto número de fatores PLSR pode resultar no ajuste excessivo do modelo, portanto, vale escolher o primeiro fator que apresente menor RMSE (WEBER et al., 2012). Os demais parâmetros estatísticos utilizados para avaliar a precisão da previsão desta PLSR estão apresentados na Tabela 16.

Pode-se observar na Tabela 16 que o modelo de calibração, contendo as 28 amostras, apresentou coeficiente de determinação (R^2) 0,73 e coeficiente de correlação (r) 0,85, valores estes que indicam que o modelo possui boa capacidade para explicar os dados e boa correlação entre as variáveis.

Tabela 16. Parâmetros estatísticos do modelo PLSR para estimativa do teor de P foliar em cultura de milho.

Etapa PLSR	r	R^2	RMSE	SEP	BIAS
Calibração (c)	0,85	0,73	0,17	0,18	0
Validação cruzada (vc)	0,71	0,51	0,24	0,25	-0,005
Predição (p)	0,76	0,59	0,32	0,29	-0,177

Dados referente a calibração (c); Dados referente a validação (vc); Dados referente a predição (p).

O $RMSE_c$ (Root Mean Square Error) indicou baixo erro na calibração, ou seja, na modelagem dos dados (0,17), enquanto o SEP_c (Standard Error of Performance), calculado como desvio padrão dos resíduos, apresentou baixa variação na precisão das previsões. O Bias, que representa a diferença sistemática entre os valores previstos e medidos, indicando tendência

de superestimação de dados quando positivo e subestimação de dados quando negativo, se encontra com valor 0 nesta fase.

No processo de validação cruzada, as mesmas amostras que compõem o modelo são utilizadas para testá-lo. Para tanto, alternadas retiradas de amostras são realizadas, as quais tem seus valores previstos pelo modelo. Nesta etapa, o sistema foi configurado para retirar uma amostra por vez. Todos os resíduos de previsão são combinados para calcular a variação residual da validação e, assim, gerados os valores dos parâmetros de avaliação desta etapa.

Nesta fase os valores de r e R^2 diminuíram (0,71 e 0,51, respectivamente), provavelmente como resultado dos erros de estimativas das amostras. O $RMSE_{vc}$ passou a ser de 0,24 e SEP_{vc} de 0,25, valores estes próximos da fase de calibração, além disso, o valor de SEP foi próximo ao valor de RMSE, dados estes que indicam boa qualidade do modelo. O Bias apresentou valor de -0,005, indicando que o modelo possui tendência de subestimação de dados extremamente baixa, confirmando sua qualidade. Segundo Willmott (1982), modelos de PLSR considerados “bons” apresentam, dentre outras coisas, o erro sistemático (Bias) próximo a zero, enquanto o erro não-sistemático (SEP) deve se aproximar do valor de RMSE.

Ramoelo et al. (2011) trabalhando com estimativa de P foliar em *Digitaria eriantha*, encontrou 4 fatores como os mais responsivos na representação dos dados, além disso, observou R^2 de 0,18 e RMSE de 0,08, utilizando 90 amostras, na fase de validação, a partir de dados espectrais coletados com o sensor Fieldspec. Já Pullanagari et al. (2016) utilizando o sensor hiperespectral AisaFENIX para estimativa de nutrientes em pastagem, observou R^2 de 0,54 e $RMSE_{cv}$ de 0,041 na estimativa de P foliar, utilizando 56 amostras.

Após a etapa da validação cruzada utilizando 28 amostras, o modelo foi testado avaliando a capacidade de predição de novas amostras a partir de dados que não participaram na construção do modelo PLSR (8 amostras). Nesta fase observa-se aumento do R^2 para 0,59, indicando boa capacidade do modelo na estimativa de dados. O coeficiente de correlação aumentou para 0,76 e Bias de -0,17, sendo este o valor médio dos resíduos.

Quanto ao $RMSE_p$, o valor foi de 0,32, indicando erro na predição de aproximadamente 0,32 g kg de P foliar, medida esta que representa os dados desde que as novas amostras usadas sejam semelhantes as amostras de calibração. Já o SEP_p apresentou valor de 0,29 nesta etapa. Ambos $RMSE_p$ e SEP_p não apresentaram aumento substancial em comparação a fase de calibração, mesmo com reduzido número de amostras, indicando estabilidade do modelo. Na Tabela 17 pode ser observado os valores de referência (obtidos por análise química) e estimados pelo modelo utilizando as 8 amostras.

Tabela 17. Valores de referência do teor de P foliar e valores estimados pelo modelo PLSR.

Amostra	Referência	Estimado	Diferença
	g kg ⁻¹		
T1-Bloco 1	1,99	1,98	0,01
T3-Bloco 1	1,82	1,71	0,11
T5-Bloco 3	2,53	2,30	0,23
T2-Bloco 4	3,04	2,98	0,06
T5-Bloco 1	2,48	2,43	0,05
T1-Bloco 4	3,19	2,31	0,88
T3-Bloco 2	2,39	2,28	0,11
T2-Bloco 3	2,40	2,44	-0,04

Comparado aos macronutrientes nitrogênio e potássio, o P geralmente encontra-se em pequena quantidade na folha. Para milho segunda safra os valores de referência são 27-35 g kg⁻¹ pra N, 17-35 g kg⁻¹ para K e 1,9 a 4,0 g kg⁻¹ para P (SBCS/NEPAR, 2017). Ainda assim, nota-se boa capacidade preditiva para o modelo elaborado, com diferenças do valor de referência variando de 0,01 g a 0,23 g de P foliar em sua maioria, e apenas uma amostra com aproximadamente 0,88 g de erro.

Quanto aos parâmetros de avaliação do modelo obtido, resultados semelhantes foram obtidos por Li, L. et al. (2018), trabalhando com dados hiperespectrais do dossel de cultura de colza (*Brassica napus*), usando espectrorradiômetro, observaram R² de 0,74 e RMSE de 0,06 na fase de calibração, para dados espectrais da planta submetida a diferentes doses de fósforo, utilizando 93 amostras. Já na fase de predição, os autores encontraram valor de R² 0,69 e RMSE 0,04 utilizando 63 amostras. Quanto aos fatores latentes, estes autores encontraram 4 fatores para melhor representação dos dados.

Zhai et al. (2013) estudando reflectância espectral de folhas de arroz, milho, gergelim, soja, chá, grama, caramanchão e arbusto em laboratório, a partir de um espectrorradiômetro, para fim de estimativa de nutrientes foliares, encontraram 6 fatores latentes como melhor representantes das amostras, R² de 0,44 e RMSE de 0,09, utilizando 65 amostras, na fase de calibração de dados de P foliar. Já na etapa de predição, obtiveram R² de 0,39 e RMSE de 0,103, a partir de 29 amostras.

Yanli et al. (2015) trabalhando com imagens hiperespectrais, obtidas em laboratório, de folhas de citrus, e obtiveram R² de 0,91 e RMSE de 0,23 na fase de calibração de dados de P foliar, utilizando 100 amostras. Já na fase de predição, os resultados foram de R² de 0,92 e RMSE de 0,05, utilizando 35 amostras.

Na Figura 20 encontram-se os coeficientes da regressão PLSR para predição da concentração de P foliar em plantas de milho. Observa-se influência em grande parte do espectro Vis/NIR, contudo, os picos situam-se nos comprimentos de onda de 450, 527, 570-642, 719, 740-796 e 980-989 nm. Na região do visível a correlação provém da absorção da radiação eletromagnética pelos pigmentos (principalmente a clorofila), enquanto a região do infravermelho próximo indica influência das estruturas foliares internas na reflectância (ADAMS et al., 1999; GASPAROTTO, 2014; GATER et al., 1965; HATFIELD et al., 2008).

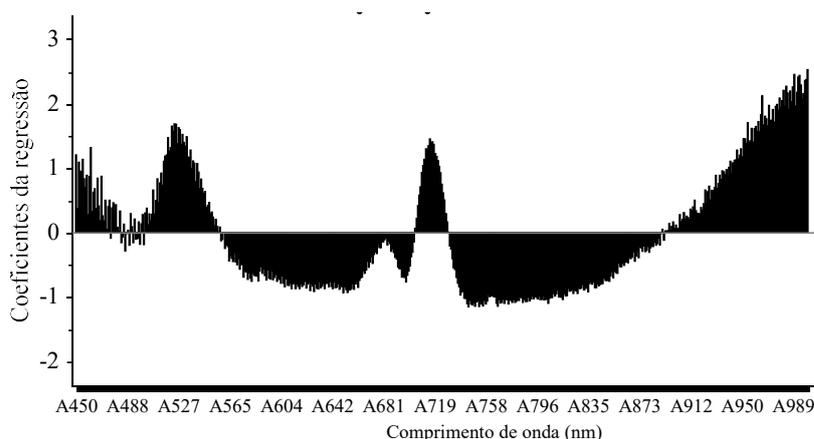


Figura 20. Coeficientes do modelo de regressão PLSR para predição do teor de P foliar.

Li, L. et al. (2018) observou correlação de teores foliares de P na faixa de 410-715 nm, atribuindo este fato a absorção da REM pela clorofila, também na faixa de 745-1100 nm, que atribuiu ao índice de área foliar e biomassa foliar influenciados pela nutrição de N e P, citando particularmente os comprimentos de onda 755, 832, 891, 999, 1196 e 1267, corroborando os dados deste trabalho até a região do infravermelho próximo.

Para estudos futuros, recomendamos trabalhar a técnica de PLSR na estimativa de quantidade de nutriente foliar em diferentes estádios fenológicos, para fins de comparação entre estes e observar se algum apresenta melhor ajuste de predição. A utilização de maior quantidade de amostras provavelmente pode levar a um modelo mais abrangente e diminuir os erros de predição.

5.6 Análise e modelos de predição dos dados de produtividade

Todos os esforços voltados para manutenção de culturas são em prol do produto final, neste caso, produtividade de grãos, que é a fonte de renda do agricultor. Assim, após analisar o comportamento espectral da cultura em função dos tratamentos, identificar as bandas que melhor caracterizam a variável em estudo a partir da análise discriminante, testar o desempenho

dos índices de vegetação na diferenciação de tratamentos e construir e testar modelos para predição de P foliar, serão analisados os dados de produtividade e comparados aos dados espectrais e em seguida construído modelo de predição de produtividade a partir da técnica PLSR.

5.6.1 Relação entre dados de produtividade e curvas espectrais

A análise de variância dos dados de produtividade resultou em diferença significativa entre os tratamentos ($p \leq 0,05$) para ambos os experimentos, os quais são representados por duas diferentes fontes de adubo fosfatado: Monoamônio Fosfato e Superfosfato Simples. Em seguida procedeu-se o teste t para comparação das médias, ao nível de 5% de probabilidade de erro (Figura 21).

Referente ao experimento com fertilizante MAP (Figura 21-A) foi observado diferença gradual de valores de produtividade dentre os tratamentos, com T5 diferindo significativamente de todos os demais tratamentos, enquanto T4 e T3 também diferiram de T2 e T1. Os tratamentos T1 e T2 tiveram valor de produtividade muito próximos, indicando que a dose de 30 kg ha⁻¹ de P₂O₅, quando se trata do adubo MAP imposto as condições deste trabalho, não é suficiente para demandar produtividade significativamente maior para esta cultura do que um tratamento sem adubação.

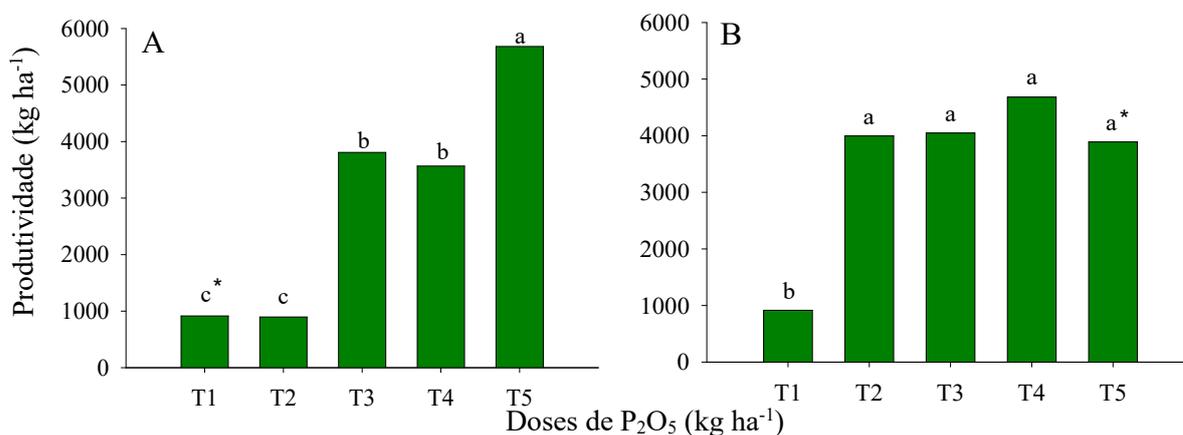


Figura 21. Produtividade da cultura de milho segunda safra sob diferentes fontes e doses de adubo fosfatado; Monoamônio fosfato (A) e superfosfato simples (B). T1, T2, T3, T4 e T5 (0, 30, 60, 120 e 240 kg ha⁻¹ P₂O₅, respectivamente). *Médias seguidas pela mesma letra na coluna não diferem estatisticamente entre si pelo teste t a 5% de probabilidade de erro.

A ausência de diferença significativa entre T3 e T4 indicam que as doses de 60 e 120 e, provavelmente, todo intervalo dentre essas doses, demandam produtividade relativamente semelhante para a cultura. Já T5 demonstrou maior valor de produtividade, contudo, a

quantidade de adubo aplicada é o dobro da recomendada para a cultura de milho segunda safra, cabendo análise de custo/benefício para tomada de decisão quanto a utilização desta dose.

O comportamento das curvas espectrais demonstrou a distinção destes tratamentos de forma semelhante, onde T1 e T2 apresentavam-se como os tratamentos mais debilitados (maior valor de reflectância na região visível e menor na região NIR) em comparação aos demais. Enquanto isso, T3, T4 e T5 demonstravam pouca diferença entre si, contudo, era notável estes serem tratamentos distintos e T5 ser o melhor tratamento dentre estes.

Quanto ao experimento referente ao fertilizante SS (Figura 21-B), apenas a testemunha diferiu significativamente dos demais tratamentos, indicando que quando se trata do fertilizante fosfatado superfosfato simples, submetido as condições deste trabalho, as plantas respondem com valores de produtividade estatisticamente semelhantes em função das doses aqui utilizadas. Numericamente o tratamento composto pela dose de adubação recomendada para a cultura (T4) demonstrou maior valor de produtividade.

Nas curvas espectrais referente a este experimento, também é possível notar tendência semelhante aos valores de produtividade, caracterizada por diferença evidente de T1 perante os demais, o qual apresentava-se como o tratamento mais debilitado, e o restante dos tratamentos com respostas espectrais muito próximas e semelhantes.

Esta uniformidade entre dados de produtividade e espectrais é esperado, visto que ambos respondem ao estado nutricional da planta (neste caso, em função de níveis de nutrição por fósforo), conforme explicado no Tópico 5.2 (curvas espectrais) e visto neste tópico. Assim, os dados de reflectância referentes as curvas espectrais foram submetidos a modelagem pelo método de Regressão por Quadrados Mínimos Parciais (PLSR) com objetivo de obter modelos preditivos de produtividade a partir das respostas espectrais da cultura.

5.6.2 Modelos de predição de produtividade utilizando Partial Least Square Regression (PLSR)

A partir do conjunto de dados composto por bandas espectrais e valores de produtividade para cada parcela experimental, foi elaborado modelo de estimativa de produtividade de grãos para plantas de milho segunda safra em função das respostas espectrais da cultura, utilizando o método PLSR. Considerando a finalidade do processo, neste momento, as duas fontes de adubo fosfatado serão consideradas um mesmo conjunto de dados, totalizando 36 amostras (parcelas experimentais).

O processo foi realizado para os estádios V6, V7 e VT com o objetivo de identificar, dentre estes, o estádio que resulte no modelo mais promissor para predição de produtividade. Para tanto, a precisão e qualidade do modelo são avaliados a partir dos parâmetros observados na (Tabela 18).

Tabela 18. Parâmetros estatísticos do modelo PLSR para estimativa de produtividade em diferentes estádios fenológicos na cultura de milho.

Estádio	Etapa PLSR	r	R ²	RMSE	SEP	Bias
V6	Calibração (c)	0,86	0,74	446,17	454,67	0
	Validação cruzada (vc)	0,78	0,61	598,94	614,49	3,67
	Predição (p)	0,91	0,84	396,94	416,05	78,13
V7	Calibração	0,86	0,74	442,80	451,23	0
	Validação cruzada	0,77	0,60	634,93	651,31	-11,94
	Predição	0,91	0,83	427,86	450,41	74,54
VT	Calibração	0,86	0,74	439,31	447,68	0
	Validação cruzada	0,81	0,66	554,02	568,37	-6,78
	Predição	0,84	0,72	460,61	419,60	241,05

Dados referente a calibração (c); Dados referente a validação (vc); Dados referente a predição (p).

Das 36 amostras totais foram selecionadas, aleatoriamente, 28 amostras para construção do modelo e 8 amostras para testar a predição deste, as quais foram utilizadas como padrão para modelagem e predição de dados de todos os estádios estudados. A distribuição dos dados foi avaliada pelas ferramentas Hotelling's T² (a 5% de probabilidade de erro) e Leverage, utilizados na identificação de outliers, os quais devem ter seus dados e influência avaliados para tomada de decisão de manter ou retirar a amostra da construção do modelo.

A partir da Tabela 18, observa-se que VT apresentou valor de r e R² igual aos demais estádios na fase de calibração (0,86 e 0,74, respectivamente) e bem próximos nas fases de validação cruzada, assim como os valores de RMSE e SEP para fase de calibração e validação. Contudo, o valor de Bias na fase de predição (241,05) foi aproximadamente três vezes maior que nos demais estádios, indicando maior tendência de superestimação de valores no momento da predição. RMSE_p apresentou o maior valor neste estádio, no qual também foi observado o menor R².

Entre V6 e V7, os valores de r, R² e Bias para todas as etapas da PLSR foram semelhantes. Contudo, o estádio V7 demonstrou valores superiores para os erros RMSE e SEP, principalmente nas etapas de validação cruzada e predição. Segundo Shaibu et al. (2015) quanto maior o R² e menor o RMSE, maior a precisão e a exatidão do modelo para prever o rendimento

de grãos. Sendo assim, os dados espectrais referentes ao estágio V6 demonstraram melhor aptidão à modelagem e predição de produtividade. Osborne et al. (2004), trabalhando com doses de fósforo em milho, observou maiores correlações (R^2) entre dados espectrais e produtividade de grãos no estágio vegetativo (V5-V7). Assim, mais informações referentes a aplicação da PLSR para o estágio V6 será abordada a seguir.

A partir da Tabela 18 pode-se observar que o modelo de calibração, contendo as 28 amostras, apresentou coeficiente de determinação (R^2) 0,74 e coeficiente de correlação (r) 0,86, valores estes que indicam que o modelo possui boa capacidade para explicar os dados e boa correlação entre as variáveis.

O $RMSE_c$ apresentou valor de erro de 446,17 na fase de calibração, ou seja, na modelagem dos dados, e SEP_c de 454,67, calculado como desvio padrão dos resíduos. O Bias se encontra em valor 0 nesta fase. O número de fatores necessários para explicar a maior parte da variação entre as variáveis em estudo e com menor valor de RMSE foram 4 fatores.

No processo de validação cruzada, no qual as mesmas amostras que compõem o modelo são utilizadas para testá-lo, os valores de r e R^2 diminuíram (0,78 e 0,61, respectivamente). O $RMSE_{vc}$ passou a ser de 598,94 e SEP_{vc} de 614,49 valores estes superiores a fase de calibração, provavelmente devido aos resíduos estimados pelo próprio processo, contudo, os valores dos dois parâmetros foram próximos, o que indica boa qualidade do modelo (WILLMOTT, 1982). O Bias apresentou valor de 3,67, indicando que o modelo possui baixa tendência de superestimação de dados, confirmando sua qualidade.

Após a etapa da validação cruzada utilizando 28 amostras, o modelo foi testado avaliando a capacidade de predição de novas amostras a partir de dados que não participaram da construção do modelo (8 amostras). Nesta fase observa-se aumento do R^2 para 0,84, demonstrando bom desempenho do modelo, visto tal valor na predição de amostras até então desconhecidas pelo modelo. O coeficiente de correlação aumentou para 0,91 e Bias de 78,13, indicando razoável superestimação de dados.

Quanto ao $RMSE_p$, foi observado diminuição do erro, com valor de 396,94, indicando erro na predição de aproximadamente 396,94 kg ha⁻¹ de produtividade. Já o SEP_p apresentou valor de 416,05 nesta etapa. Ambos $RMSE_p$ e SEP_p apresentaram valores próximos as demais etapas, indicando estabilidade do modelo. Na Tabela 19 pode ser observado os valores de referência (obtidos a partir da colheita de grãos) e estimados pelo modelo, utilizando as 8 amostras.

A partir da Tabela 19, observa-se diferenças que variam de 36,8 a 679,2 kg ha⁻¹ entre o valor referência e o valor estimado, valores estes que podem ser considerados relativamente satisfatórios visto que uma variável complexa como a produtividade, que envolve fatores internos e externos a planta, está tendo seus valores estimados por dados espectrais obtidos em estágio inicial da cultura (V6).

Tabela 19. Valores de referência de produtividade e valores estimados pelo modelo PLSR, para milho em estágio V6.

Amostra	Referência	Estimado	Diferença
	kg ha ⁻¹		
T1-Bloco 2	288,5	325,3	36,8
T3-Bloco 3	2.703,6	2.400,1	303,5
T5-Bloco 4	3.510,1	2.830,9	679,2
T2-Bloco 1	2.512,3	2.968,3	-456,0
T4-Bloco 4	1.726,6	2.086,4	-359,8
T2-Bloco 4	642,3	700,1	-57,8
T5-Bloco 3	2.154,2	2.256,2	-102,0
T3-Bloco 3	1.864,5	2.460,0	-595,5

Na literatura, até então, existem poucos trabalhos relacionando comportamento espectral de culturas em função de doses de adubação fosfatada à estimativa de produtividade. Dentre estes, podemos citar Zhang e He (2013), analisando o comportamento espectral da cultura de colza sob diferentes doses de nitrogênio, fósforo e potássio, aplicaram a técnica PLSR para predição de produtividade, no qual encontraram R² de 0,69, e RMSE de 27,41 g planta⁻¹ na fase de calibração, no estágio de fechamento de linha da cultura.

Weber et al. (2012) trabalhando com cultura de milho imposta a condições de estresse hídrico, observaram 5 fatores para representação dos dados, R² de 61,2 e RMSE de 550 kg ha⁻¹ de produtividade na fase de calibração, a partir de dados de reflectância do dossel da cultura que se encontrava em estágio vegetativo. Já na fase de validação, os autores obtiveram R² de 20,3 e RMSE de 1.140 kg ha⁻¹ de produtividade. No trabalho destes autores, o início do estágio reprodutivo foi a fase de melhor modelagem de dados, a qual foi atribuída 7 fatores para representação dos dados, R² de 68,5 e RMSE de 470 kg ha⁻¹ de grãos na fase de calibração, e R² de 39,8 e RMSE de 640 kg ha⁻¹ na fase de validação do modelo.

Enquanto isso, Barmeier et al. (2017) tiveram como objetivo em seu trabalho, desenvolver modelos de PLSR que pudessem prever o rendimento de grãos de cevada a partir de dados espectrais da cultura, a qual foi submetida a diferentes doses de adubação nitrogenada, estudando dados coletados por três anos consecutivos. A partir da técnica, os autores obtiveram

R^2 variando entre 0,74 e 0,95, e RMSE entre 673,15 e 2.967 kg ha⁻¹, e consideraram promissora a utilização desta ferramenta preditiva. Ainda acrescentaram que a vantagem da PLSR é a análise simultânea de várias variáveis preditivas, o que pode melhorar a estabilidade do modelo.

Sharabian et al. (2014) trabalhando com adubação nitrogenada em cultura de trigo, utilizaram dados espectrais para estimativa de rendimento de grãos da cultura a partir da técnica PLSR. Os autores obtiveram 6 fatores como melhor representante dos dados, R^2 de 0,66 e RMSE de 789 kg ha⁻¹ na fase de calibração, já na fase de validação, o R^2 foi de 0,73 e RMSE de 719 kg ha⁻¹. Já Li, Y. et al. (2017) trabalhando também com trigo, porém, variando níveis de cobertura vegetal, obtiveram R^2 de 0,77 e RMSE de 0,32 kg m² na estimativa de biomassa a partir de PLSR, na fase de calibração, e R^2 de 0,63 e RMSE de 0,51 kg m² na fase de validação.

Quanto aos coeficientes da regressão PLSR para predição de produtividade (Figura 22), observa-se influência em grande parte do espectro Vis/NIR, contudo, os picos situam-se nos comprimentos de onda de 450-490, 544, 659, 720 e 990 nm.

Zhang e He (2013) trabalhando com níveis de fósforo, nitrogênio e potássio em cultura de colza verificaram grande influência dos comprimentos de onda 543, 686, 718, 741, 824 e 994 nm, na predição de produtividade pelo método de PLSR, valores próximos aos encontrados neste trabalho, corroborando com este estudo.

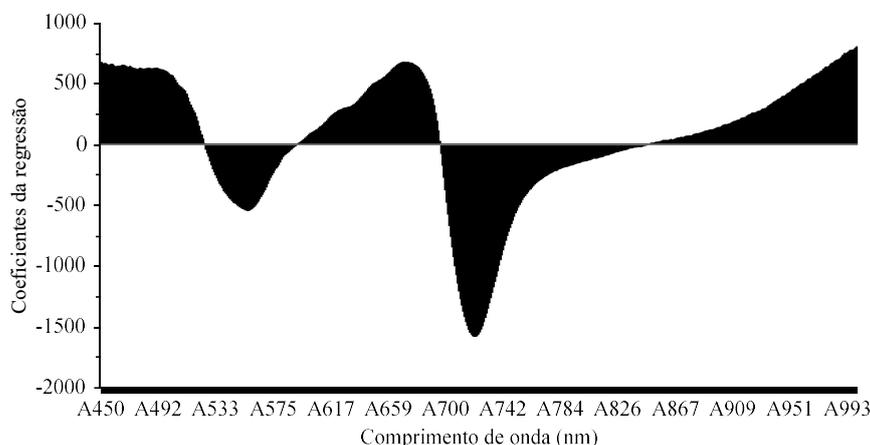


Figura 22. Coeficientes do modelo de regressão PLSR para predição de produtividade.

A partir dos dados, foi observado que V6 foi o melhor estágio para estimativa de produtividade da cultura, o que é importante visto que é uma fase vegetativa inicial e medidas ainda podem ser tomadas caso seja constatado valores muito baixos da variável em análise. A utilização de maior quantidade de amostras pode levar a um modelo mais abrangente e diminuir os erros de predição, assim, mais estudos devem ser realizados para aperfeiçoamento da técnica.

6. CONCLUSÕES

O comportamento espectral da cultura de milho segunda safra apresenta diferenças de acordo com os níveis de nutrição da planta promovidos por adubo fosfatado, no qual é possível distinguir plantas sob severa deficiência nutricional por ausência ou baixas doses de adubo fosfatado de plantas bem nutridas por doses maiores do fertilizante, por meio de diferenças na reflectância. Contudo, plantas submetidas a doses intermediárias são de difícil identificação por este método, por apresentarem diferenças pouco visíveis.

Os modelos discriminantes permitiram a identificação e classificação de níveis nutricionais de fósforo em plantas de milho. Os erros na classificação foram condizentes as particularidades da interação do fertilizante com solo e planta nos experimentos.

Os índices de vegetação obtidos por dados espectrais coletados por espectrorradiômetro, foram capazes de distinguir tratamentos com severa deficiência nutricional de tratamentos cujas plantas encontravam-se bem nutridas, enquanto tratamentos com nutrição intermediária não foram diferenciados dos tratamentos com maiores doses de adubação.

Os IV's obtidos por dados coletados pelas câmeras digitais seguiram o mesmo padrão, contudo, no estágio R1, para fonte de adubo MAP, foi observada exceção, onde o tratamento composto por fome oculta pôde ser diferenciado estatisticamente do tratamento representado pela maior dose de adubação ($240 \text{ kg ha}^{-1} \text{ P}_2\text{O}_5$), indicando melhor desempenho de dados obtidos do dossel da cultura na diferenciação de tratamentos. Os IV's GRVI e RVI foram os mais eficientes na diferenciação dos tratamentos.

A modelagem dos dados de reflectância espectral, obtidos por espectrorradiômetro, a partir da técnica PLSR, apresentaram elevado potencial para predição de fósforo foliar e produtividade. Quanto a produtividade, o estágio fenológico mais promissor para predição foi V6.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ADAMS, M. L.; PHILPOT, W.D.; NORVELL, W.A. Yellowness index: An application of spectral second derivatives to estimate chlorosis of leaves in stressed vegetation, **International Journal of Remote Sensing**, v. 20, n. 18, p. 3663–3675, 1999.
- AL-ABBAS, A. H.; BARR, R.; HALL, J. D.; CRANE, F. L.; BAUMGARDNER, M. F. Spectra of Normal and Nutrient-Deficient Maize Leaves 1. **Agronomy Journal**, v. 66, n. 1, p. 16-20, 1974.
- ALMEIDA, M. R. N. **Espectroscopia de Infravermelho Próximo com Transformada de Fourier (FTNIR) na Caracterização de Farinhas para Alimentação Pueril**. 84 p. Dissertação (mestrado). Universidade de Lisboa, 2009.
- ARANTES, B. H. T.; ARANTES, L. T.; TONDATO, C. Identificação de ferrugem na soja por meio de sensores multiespectrais. **Revista do Agronegócio – Reagro**, v. 5, n. esp., p. 38-44, 2016.
- ARNON, D. I.; STOUT, P. R. The essentiality of certain elements in minute quantity for plants with special reference to copper. **Plant Physiology**, v. 14, n. 2, p. 371-375, 1939.
- ASD Inc. **ViewSpec Pro User’s Guide**: ViewSpec Pro™ User Manual. ASD Document 600555 Rev. A, 2008.
- BARMEIER, G.; HOFER, K.; SCHMIDHALTER, U. Mid-season prediction of grain yield and protein content of spring barley cultivars using high-throughput spectral sensing. **European journal of agronomy**, v. 90, p. 108-116, 2017.
- BAUSCH, W. C.; DUKE, H. R. Remote sensing of plant nitrogen status in corn. **Transactions of ASAE**, v. 39, n. 5, p. 1869-1875, 1996.
- BEDIN, I.; FURTINI NETO, A. E.; RESENDE, A. V.; FAQUIN, V.; TOKURA, A. M. SANTOS, J. Z. L. Fertilizantes fosfatados e produção de soja em solos com diferentes capacidades tampão de fosfato. **Revista Brasileira de Ciência do Solo**, v. 27, n. 4, p. 639-646, 2003.
- BIRTH, G. S.; MCVEY G. R. Measuring color of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, v. 60, n. 6, p. 640-649, 1968.
- BOGREKCI, I.; LEE, W. S.; JORDAN, J. D. Airborne hyperspectral imaging for sensing phosphorus concentration in the Lake Okeechobee drainage basin. In Proc. SPIE Defense & Security Symposium, v. 5795, p. 106-112, **Chemical and Biological Sensing VI**. P. J. Gardner, 2005.
- BORGES, I. D. **Marcha de absorção de nutrientes e acúmulo de matéria seca em milho**. 132 p. Tese (Doutorado em Agronomia) – Universidade Federal de Lavras, Lavras/MG, 2006.
- BRASIL. MINISTÉRIO DA AGRICULTURA PECUÁRIA E MEIO AMBIENTE - MAPA. Instrução Normativa nº 53, de 23 de outubro de 2013. **Diário Oficial da União**, Brasília, DF, outubro de 2013.

BRASIL. MINISTÉRIO DA AGRICULTURA PECUÁRIA E MEIO AMBIENTE - MAPA. Instrução Normativa nº 6, de 10 de março de 2016. **Diário Oficial da União**, Brasília, DF, março de 2016.

BRASIL. MINISTÉRIO DA AGRICULTURA PECUÁRIA E MEIO AMBIENTE - MAPA. Instrução Normativa MAPA nº 39, de 8 de agosto de 2018: Anexo I. **Diário Oficial da União**, Brasília, DF, agosto de 2018.

BULL, L. T. Nutrição mineral do milho. In: BULL, L. T.; CANTARELLA, H. (Ed.) **Cultura do milho: fatores que afetam a produtividade**. Piracicaba: POTAFOS, 1993. p. 63-145.

CAIONE, G.; FERNANDES, F. M.; LANGE, A. Efeito residual de fontes de fósforo nos atributos químicos do solo, nutrição e produtividade de biomassa da cana-de-açúcar. **Revista Brasileira de Ciências Agrárias**, v. 8, n. 2, p. 189-196, 2013.

CANAVESI, V.; PONZONI, F. J.; VALERIANO, M. M. Estimativa de volume de madeira em plantios de *Eucalyptus* spp. utilizando dados hiperespectrais e dados topográficos. **Revista Árvore**, v. 34, n. 3, p. 539-549, 2010.

CANDIAGO, S.; REMONDINO, F.; GIGLIO, M.; DUBBINI, M.; GATTELLI, M. Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. **Remote sensing**, v. 7, n. 4, p. 4026-4047, 2015.

CARVALHO, A. M.; SILVA, S. D.; LEITE, R. L. L.; PEREIRA, R. S.; BARROS, A. P.; SILVA, L. S.; SOUSA, R. R. Avaliação de níveis de P no cultivo do milho em região de transição Cerrado-Amazônia. **Global Science and Technology**, v. 10, n. 2, p. 14-24, 2017.

CARVALHO, J. F. C.; CRUSIOL, L. G. T.; PERINI, L. J.; SIBALDELLI, N. R.; FERREIRA, L. C.; MARCELINO-GUIMARÃES, F. C.; NEPONUCENO, A. L.; NEUMAIER, N.; FARIAS, J. R. B. Phenotyping soybeans for drought responses using remote sensing techniques and non-destructive physiological analysis. **Global Science and Technology**, v. 8, n. 2, p. 1, 2015.

CASTRO, L. R.; REIS, T. C.; FERNANDES JÚNIOR, O.; ALMEIDA, R. B. S.; ALVES, D. S. Doses e formas de aplicação de fósforo na cultura do milho. **Revista Agrarian**, v. 9, n. 31, p. 47-54, 2016.

CATANI, R. **Monitoramento temporal da cultura da soja através do sensoriamento remoto com a utilização de um RPA**. 51 p. Trabalho de conclusão de curso (Graduação em Engenharia Agrônômica) – Universidade Tecnológica Federal do Paraná, Pato Branco, 2018.

CEZAR, E.; NANNI, M. R.; DEMATTÊ, J. A. M.; CHICATI, M. L.; BERTI DE OLIVEIRA, R. Estimativa de atributos do solo por meio de espectrorradiometria difusa. **Revista Brasileira de Ciência do Solo**, v. 37, n. 4, p. 858-868, 2013.

CHANDEL, N. S.; TIWARI, P. S.; SINGH, K. P.; JAT, D.; GAIKWAD, B. B.; TRIPATHI, H.; GOLHANI, K. Yield prediction in wheat (*Triticum aestivum* L.) using spectral reflectance índices. **CURRENT SCIENCE**, v. 116, n. 2, p. 272, 2019.

CHICATI, M. S. **Resposta espectral da cultura do feijão e sua relação com parâmetros biofísicos em diferentes doses de nitrogênio**. 114 p. Dissertação (Mestrado em Agronomia) – Universidade Estadual de Maringá (UEM), Maringá, 2015.

COELHO, A. M. Nutrição e adubação do milho. **Embrapa Milho e Sorgo. Circular técnica**, 2006.

COLEMAN, T. L.; MONTGOMERY, O. L. Soil Moisture, organic matter and iron content effect on the spectral characteristics of selected vertisols and alfisols in Alabama. **Photogrammetric Engineering and Remote Sensing**, v. 53, n. 12, p. 1659-1663, 1987.

COLEMAN, T. L.; AGBU, P. A.; MONTGOMERY, O. L.; GAO, T.; PRASAD, S. Spectral band selection for quantifying selected properties in highly weathered soils. **Soil Science**, v. 151, n. 5, p. 355-361, 1991.

CNA – Confederação da Agricultura e Pecuária do Brasil. **Balanco 2019**. Disponível em: <<https://www.cnabrazil.org.br/paginas-especiais/balanco-2019-e-perspectivas-2020#>>. Acesso em: 6 jan. 2020.

COELHO, A. M.; FRANÇA, G. E. **Nutrição e adubação: seja doutor do seu milho**. Piracicaba: POTAFOS, 1995. 9 p.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da safra brasileira de grãos**. Terceiro levantamento, dezembro 2019, v. 7, n. 3, 2019.

CONTINI, E.; MOTA, M. M.; MARRA, R.; BORGHI, E.; MIRANDA, R. A.; SILVA, A. F.; SILVA, D. D.; MACHADO, J. R. A.; COTA, L. V.; COSTA, R. V.; MENDES, S. M. Milho: Caracterização e Desafios Tecnológicos. **Embrapa Milho e Sorgo-Nota Técnica/Nota Científica (ALICE)**, 2019.

COUTINHO, E. L. M.; NATALE, W.; VILLA NOVA, A. S.; SITTA, D. S. X. **Eficiência agrônômica de fertilizantes fosfatados para a cultura da soja**. Pesquisa Agropecuária Brasileira, v. 26, n. 9, p. 1393-1399, 1991.

CRUSIOL, L. G. T.; CARVALHO, J. F. C.; SIBALDELLI, R. N. R.; NEIVERTH, W.; RIO, A.; FERREIRA, L. C.; PROCÓPIO, S. O.; MERTZ-HENNING, L. M.; NEPOMUCENO, A. L.; NEUMAIER, N., FARIAS, J. R. B. NDVI variation according to the time of measurement, sampling size, positioning of sensor and water regime in different soybean cultivars. **Precision agriculture**, v. 18, n. 4, p. 470-490, 2017.

CRUSIOL, L. G. T. **Dados multi e hiperespectrais da cultura da soja (Glycine Max L.) e sua relação com doses de gesso e calcário no solo**. 118 p. Dissertação (Mestrado em Agronomia) – Universidade Estadual de Maringá (UEM), Maringá, 2017.

CRUZ, C. V.; FERNANDES, D. M.; GROHSKOPF, M. A.; CRUZ, I. V. Corn fertilization with triple superphosphate in a Typic Hapludox soil under the residual effect of alternative phosphorus sources. **Revista de Ciências Agroveterinárias**, v. 17, n. 2, p. 166-173, 2018.

DELGADO, R. C.; SEDIYAMA, G. C.; LIMA, E. P.; ANDRADE, R. G.; SOUZA, L. P.; PEREIRA, F. A. Classificação espectral de áreas plantadas com as culturas do milho e feijão

por meio da árvore de decisão. In: Embrapa Solos-Artigo em anais de congresso (ALICE). In: **Anais do Simpósio Brasileiro de Sensoriamento Remoto**, São José dos Campos: INPE, 2013.

EL-HENDAWY, S.; AL-SUHAIBANI, N.; ELSAYED, S.; REFAY, Y.; ALOTAIBI, M.; DEWIR, Y. H.; HASSAN, W.; SCHMIDHALTER, U. Combining biophysical parameters, spectral indices and multivariate hyperspectral models for estimating yield and water productivity of spring wheat across different agronomic practices. **PloS one**, v. 14, n. 3, p. 1-26, 2019.

EPIPHANIO, J. C. N.; GLERIANI, J. M.; FORMAGGIO, A. R.; RUDORFF, B. F. T. Índices de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa agropecuária brasileira**, Brasília, v. 31, n. 6, p. 445 – 454, 1996.

FALCIONI, R. MORIWAKI, T.; BONATO, C. M.; SOUZA, L. A.; NANNI, M. R.; ANTUNES, W. C. Distinct growth light and gibberellin regimes alter leaf anatomy and reveal their influence on leaf optical properties. **Environmental and experimental botany**, v. 140, p. 86-95, 2017.

FANCELLI, A. L. **Plantas alimentícias: guia para aula, estudos e discussão**. Piracicaba: ESALQ, 1986. 131 p.

FAQUIN, V. **Nutrição Mineral de Plantas**. Lavras: UFLA / FAEPE, 2005. 186 p.

FERNANDES, M. S. **Nutrição mineral de plantas**. Sociedade Brasileira de Ciência do solo, 2006. 432p.

FERNANDES, P. **Estimativa da produtividade de milho (*Zea mays* L.) através de imagens multiespectrais obtidas por veículo aéreo não tripulado**. 79 p. Dissertação (Mestrado em Agricultura de Precisão) – Universidade Federal de Santa Maria, Santa Maria, 2016.

FIORIO, P. R.; GADY, A. P. B.; TAVARES, T. R.; MARTELLO, M.; DEMATTÊ, J. A. M.; MOLIN, J. P. Análise discriminante utilizando-se dados hiperespectrais no diferencial de doses de nitrogênio em cana-de-açúcar. In: Simpósio Brasileiro de Sensoriamento Remoto, **Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto**, Santos, INPE, 2017.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. 3ª Ed. Ampliada e atualizada. São Paulo: Oficina de Textos, 2011.

FONSECA, A. D.; FERNANDES, J. C. **Detecção remota**. Lisboa: Lidel, 2004. 224p.

FREIRE, M. L. F. **Alterações espectrais, agronômicas, de desenvolvimento e crescimento do amendoim causadas por doses de cálcio e fósforo em condições de casa-de-vegetação**. 207 p. Tese (Doutorado em Recursos Naturais) – Universidade Federal de Campina Grande (UECG), Campina Grande, 2004.

FURLANETTO, R. H. **Sensores multi e hiperespectrais na identificação e quantificação da deficiência de potássio na cultura do milho (*Zea mays*)**. 133 p. Dissertação (Mestrado em Agronomia) – Universidade Estadual de Maringá (UEM), Maringá, 2018.

GARSON, G. D. Partial least squares: Regression and structural equation models. **Asheboro, NC: Statistical Associates Publishers**, 2016.

GASPAROTTO, A. C. **Obtenção de imagens digitais e espectrometria da cultura do milho e sua relação com produtividade em diferentes doses de nitrogênio**. 126 p. Dissertação (Mestrado em Agronomia) – Universidade Estadual de Maringá (UEM), Maringá, 2014.

GATES, D.M.; KEEGAN, H.J.; SCHLETER, J.C.; WEIDNER, V.R. Spectral properties of plants. **Applied Optics**, v. 4, n. 1, p. 11-20, 1965.

GITELSON, A.A.; Y.J. KAUFMAN; MERZLYAK, M.N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote sensing of Environment**, v. 58, n. 3, p. 289-298, 1996.

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.

GÓMEZ-CASERO, M. T.; LÓPEZ-GRANADOS, F.; PEÑA-BARRAGÁN, J. M.; JURADO-EXPÓSITO, M.; GARCÍA-TORRES, L.; FERNÁNDEZ-ESCOBAR, R. Assessing nitrogen and potassium deficiencies in olive orchards through discriminant analysis of hyperspectral data. **Journal of the American Society for Horticultural Science**, v. 132, n. 5, p. 611-618, 2007.

GRACIA-ROMERO, A.; KEFAUVER, S. C.; VERGARA-DÍAZ, O.; ZAMAN-ALLAH, M. A.; PRASANNA, B. M.; CAIRNS, J. E.; ARAUS, J. L. Comparative performance of ground vs. aerially assessed RGB and multispectral indices for early-growth evaluation of maize performance under phosphorus fertilization. **Frontiers in plant science**, v. 8, p. 2004, 2017.

GROFF, E. C.; NANNI, M. R.; POVH, F. P.; CEZAR, E. Características agronômicas associadas com índices de vegetação medidos por sensores ativos de dossel na cultura da soja. **Semina: Ciências Agrárias**, v. 34, n. 2, p. 517-525, 2013.

GUARESCHI, R. F.; GAZOLLA, P. R.; SOUCHIE, E. L.; ROCHA, A. C. Adubação fosfatada e potássica na semeadura e a lanço antecipada na cultura da soja cultivada em solo de Cerrado. **Semina: Ciências Agrárias**, v. 29, n. 4, p. 769-774, 2008.

HADLICH, H. L. **O reconhecimento de espécies arbóreas em campo por meio da casca com o uso da espectroscopia no visível e infravermelho próximo na Amazônia Central**. 65 p. Dissertação (Mestrado em Ciências de Florestas Tropicais) – Instituto Nacional de Pesquisas da Amazônia – INPA, Manaus, 2017.

HAGIN, J.; BERKOVITS, J. Efficiency of phosphatic fertilizers of varying water solubility. **Canadian Journal of Soil Science**, v. 41, n. 1, p. 68-80, 1961.

HAIR JR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise multivariada de dados**. 6 Ed. Dados eletrônicos. Porto Alegre: Bookman, 2009. 682 p.

HATFIELD, J. L.; GITELSON, A. A.; SCHEPERS, J. S.; WALTHALL, C. L. Application of Spectral Remote Sensing for Agronomic Decisions. **Agronomy journal**, v. 100, n. 3, p. 117-131, 2008.

HUETE, A.R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**. v. 25, n. 3, p. 295-309, 1988.

JACOB, J.; LAWLOR, D. W. Stomatal and mesophyll limitations of photosynthesis in phosphate deficient sunflower, maize and wheat plants. **Journal of Experimental Botany**, v. 42, n. 8, p. 1003-1011, 1991.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos, SP: Parêntese, 2009. 598 p.

JIM, A. S. **Identificação e caracterização espectral da ferrugem (*Austropuccinia psidii*) do eucalipto por imagens de alta resolução obtidas de Veículos Aéreos Não Tripulados (VANT) e em laboratório (espectroradiômetro)**. 103 p. Tese (Doutorado em Ciência Florestal) – Universidade Estadual Paulista Júlio de Mesquita Filho, Botucatu, 2018.

JORGE, L. A. C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. **Embrapa Instrumentação-Capítulo em livro científico (ALICE)**, 2014.

KARIMI, Y.; PRASHER, S. O.; MCNAIRN, H.; BONNELL, R. B.; DUTILLEUL, P.; GOEL, P. K. Classification accuracy of discriminant analysis, artificial neural networks, and decision trees for weed and nitrogen stress detection in corn. **Transactions of the ASAE**, v. 48, n. 3, p. 1261-1268, 2005.

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

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

LEBOURGEOIS, V.; BÉGUÉ, A.; LABBÉ, S.; MALLAVAN, B.; PRÉVOT, L.; ROUX, B. Can commercial digital cameras be used as multispectral sensors? A crop monitoring test. **Sensors**, v. 8, n. 11, p. 7300-7322, 2008.

LI, D.; WANG, C.; JIANG, H.; PENG, Z.; YANG, J.; SU, Y.; SONG, J.; CHEN, S. Monitoring litchi canopy foliar phosphorus content using hyperspectral data. **Computers and electronics in agriculture**, v. 154, p. 176-186, 2018.

LI, L.; WANG, S.; REN, T.; WEI, Q.; MING, J.; LI, J.; LI, X.; CONG, R.; LU, J. Ability of models with effective wavelengths to monitor nitrogen and phosphorus status of winter oilseed rape leaves using in situ canopy spectroscopy. **Field crops research**, v. 215, p. 173-186, 2018.

LI, Y.; LIU, Y.; WU, S.; WANG, C.; XU, A.; PAN, X. Hyper-spectral estimation of wheat biomass after alleviating of soil effects on spectra by non-negative matrix factorization. **European Journal of Agronomy**, v. 84, p. 58-66, 2017.

LIU, W. T. H. **Aplicações de Sensoriamento Remoto**. Campo Grande: Uniderp, 2007. 881 p.

LOOZEN, Y.; KARSSENBERG, D.; JONG, S. M.; WANG, S.; DIJK, J. V.; WASSEN, M. J.; REBEL, K. T. Exploring the use of vegetation indices to sense canopy nitrogen to phosphorus ratio in grasses. **International Journal of Applied Earth Observation and Geoinformation**, v. 75, p. 1-14, 2019.

MAGALHÃES, P. C.; DURÃES, F. O. M. Fisiologia da Produção de Milho. **Embrapa Milho e Sorgo - Circular Técnica (INFOTECA-E)**, 2006.

MAHAJAN, G. R.; PANDEY, R. N.; SABOO, R. N.; GUPTA, V. K.; DATTA, S. C.; KUMAR, D. Monitoring nitrogen, phosphorus and sulphur in hybrid rice (*Oryza sativa* L.) using hyperspectral remote sensing. **Precision agriculture**, v. 18, n. 5, p. 736-761, 2017.

MAHAJAN, G. R.; SABOO, R. N.; PANDEY, R. N.; GUPTA, V. K.; KUMAR, D. Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur and potassium in wheat (*Triticum aestivum* L.). **Precision agriculture**, v. 15, n. 5, p. 499-522, 2014.

MALAVOLTA, E.; VITTI, G. C.; OLIVEIRA, S. A. **Avaliação do estado nutricional de plantas: princípios e aplicações**. Piracicaba: Potafos, 1997. 308 p.

MARSCHNER, P. **Marschner's Mineral Nutrition of Higher Plants**. 3 Ed. Austrália: School of Agriculture, Food and Wine - The University of Adelaide, 2012. 649 p.

MARTINS, G. D.; GALO, M. L. B. T. Caracterização espectral da cana-de-açúcar infectada por nematoides e *myndolus fryanus* por espectrorradiometria de campo. **Boletim de Ciências Geodésicas**, v. 21, n. 4, p. 783-796, 2015.

MEDEIROS, F. A. **Desenvolvimento de um veículo aéreo não tripulado para aplicação em agricultura de precisão**. 102 p. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2007.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Belo Horizonte: Editora UFV, 2005. 297 p.

MONTEIRO, J. E. **Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola**. Brasília: Instituto Nacional de Meteorologia, 2009. 530 p.

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

MORIWAKI, T.; FALCIONI, R.; TANAKA, F. A. O.; CARDOSO, K. A. K.; SOUZA, L. A.; BENEDITO, E.; NANNI, M. R.; BONATO, C. M.; ANTUNES, W. C. Nitrogen-improved photosynthesis quantum yield is driven by increased thylakoid density, enhancing green light absorption. **Plant science**, v. 278, p. 1-11, 2019.

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.

NANNI, M. R. **Dados radiométricos obtidos em laboratório e no nível orbital na caracterização e mapeamento de solos**. 366 p. Tese (Doutorado em Agronomia). Escola superior de Agricultura Luiz de Queiroz, ESALQ, Piracicaba, 2000.

NANNI, M. R.; DEMATTÊ, J. A. M. FIORIO, P. R. Análise discriminante dos solos por meio de resposta espectral no nível terrestre. **Pesquisa Agropecuária Brasileira**, v.39, n.10, p.995-1006, 2004.

NOGUEIRA, A. P. O.; SEDIYAMA, T.; CRUZ, C. D.; REIS, M. S.; PEREIRA, D. G.; JANGARELLI, M. Novas características para diferenciação de cultivares de soja pela análise discriminante. **Ciência Rural**, v. 38, n. 9, p. 2427-2433, 2008.

NOVAIS, R. F.; SMYTH, T. J. **Fósforo em solo e planta em condições tropicais**. Viçosa, MG: UFV, DPS, 1999. 399p.

NOVO, E. M. M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Edgard Blucher, 1989. 308p.

OLIVEIRA, S. B.; CAIONE, G.; CAMARGO, M. F.; OLIVEIRA, A. N. B.; SANTANA, L. Fontes de fósforo no estabelecimento e produtividade de forrageiras na região de Alta Floresta – MT. **Global Science and Technology**, v. 05, n. 1, p. 1-10, 2012.

OSBORNE, S. L.; SCHEPERS, J. S.; FRANCIS, D.; SCHLEMMER, M. R.; Detection of Phosphorus and Nitrogen Deficiencies in Corn Using Spectral Radiance Measurements. **Agronomy journal**, v. 94, n. 6, p. 1215-1221, 2002.

OSBORNE, S. L.; SCHEPERS, J. S.; SCHLEMMER, M. R. Detecting Nitrogen and Phosphorus Stress in Corn Using Multi-spectral Imagery. **Communications in soil science and plant analysis**, v. 35, n. 3-4, p. 505-516, 2004.

PASSOS, A. G.; CAVALCANTI, L. B.; OLIVEIRA, R. S. **Projeto de Veículo Aéreo Não Tripulado (VANT) agrícola**. Trabalho de conclusão de curso (Graduação em Engenharia Mecânica) – Universidade Tecnológica Federal do Paraná, Curitiba, 2014.

PAVAN, M. A.; MIYAZAMA, M. Disponibilidade do manganês no solo: dificuldades e problemas na interpretação da análise para fins de fertilidade. **Revista Brasileira de Ciência do Solo**, v. 8, n. 3, p. 285-289, 1984.

PEREIRA, B. C. B. **Análise da evolução de processos erosivos com fotografias obtidas por VANT (RPAS)**. 84 p. Trabalho de conclusão de curso (Bacharel em Geografia) – Universidade Estadual Paulista – UNESP, Ourinhos, 2017.

PERRENOUD, S. **Potassium and Plant Health**. 2 ed. Berne, International Potash Institute, 1990. 363p.

PESTANA, M. H.; GAGEIRO, J. N. **Análise de dados para ciências sociais: a complementaridade do SPSS**. 4ª ed. Lisboa: Silabo, 2005.

PIMSTEIN, A.; KARNIELI, A.; BANSAL, S. K.; BONFIL, D. Exploring remotely sensed Technologies for monitoring wheat potassium and phosphorus using field spectroscopy. **Field Crops Research**, v. 121, n. 1, p. 125-135, 2011.

PINHEIRO, H. S. K.; CHAGAS, C. S.; CARVALHO JUNIOR, W. C.; ANJOS, L. H. C. Uso de dados de sensoriamento remoto em mapeamento digital de solos por redes neurais artificiais. In: Embrapa Solos-Artigo em anais de congresso (ALICE). In: Simpósio Brasileiro de Sensoriamento Remoto, 16. 2013, Foz do Iguaçu. **Anais do Simpósio Brasileiro de Sensoriamento Remoto**, São José dos Campos: INPE, 2013.

PINTER JR, P. J.; HATFIELD, J. L.; SCHEPERS, J. S.; BARNES, E. M.; MORAN, M. S. Remote Sensing for Crop Management. **Photogrammetric Engineering & Remote Sensing**, v. 69, n. 6, p. 647-664, 2003.

PITHAN, P. A. **Dados hiperespectrais aplicados na avaliação de videiras da cultivar Cabernet Sauvignon infectadas com alguns patógenos**. 60 p. Dissertação (Mestrado em Sensoriamento Remoto) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

PONZONI, F. J. Sensoriamento remoto no estudo da vegetação: diagnosticando a mata atlântica. In: RUDORFF, B. F. T.; MORAES, E. C.; PONZONI, F. J.; CAMARGO JÚNIOR, H.; CONFORTE, J. C.; MOREIRA, J. C.; EPIPHANIO, J. C. N.; MOREIRA, M. A.; KAMPEL, M.; ALBUQUERQUE, P. C. G. de; MARTINI, P. R.; FERREIRA, S. H.; TAVARES JÚNIOR, S. S.; SANTOS, V. M. N. dos (Ed.). **Curso de uso de sensoriamento remoto no estudo do meio ambiente**. São José dos Campos: INPE, 2002. cap. 8, 27 p.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no Estudo da Vegetação**. São José dos Campos: Ed. A. Silva Vieira, 2007. 135 p.

PULLANAGARI, R. R.; KERESZTURI, G.; YULE, I. J. Mapping of macro and micro nutrients of mixed pastures using airborne AisaFENIX hyperspectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 117, p. 1-10, 2016.

RAIJ, B. V. **Fertilidade do Solo e Manejo de Nutrientes**. Piracicaba: International Plant Nutrition Institute – Brasil, 2011. 420 p.

RAMOELO, A.; SKIDMORE, A. K.; SCHLERF, M.; MATHIEU, R.; HEITKONIG, I. M. A. Water-removed spectra increase the retrieval accuracy when estimating savanna grass nitrogen and phosphorus concentrations. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 4, p. 408-417, 2011.

RAMOELO, A.; SKIDMORE, A. K.; SCHLERF, M.; HEITKONIG, I. M. A.; MATHIEU, R.; CHO, M. A. Savanna grass nitrogen to phosphorous ratio estimation using field spectroscopy and the potential for estimation with imaging spectroscopy. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, n. 1, p. 334-343, 2013.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v.43, n. 12, p.1541-1552, 1977.

RITCHIE, S.; HANWAY, J. J. **How a corn plant develops**. Ames: Iowa State University of Science and Technology/ Cooperative Extension Service, 1989. 21 p.

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

ROSA, R. **Introdução ao Sensoriamento Remoto**. 6ª. ed. Uberlândia: EDUFU, 2007. 248 p.

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

SABINS Jr., F. F. **Remote sensing: principles and interpretations**. San Francisco: W. H. Freeman, 1987. 449 p.

SAKAMOTO, T.; GITELSON, A. A.; NGUY-ROBERTSON, A. L.; ARKEBAUER, T. J.; WARDLOW, B. D. An alternative method using digital cameras for continuous monitoring of crop status. **Agricultural and Forest Meteorology**, v. 154, n. 155, p. 113– 126, 2012.

SANTOS, C. G. **Monitoramento aéreo e diagnóstico de plantas daninhas de difícil controle no sudoeste goiano**. 65 p. Dissertação (Mestrado em Bioenergia e Grãos) – Instituto Federal de Educação, Ciência e Tecnologia Goiano, Rio Verde, 2019.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; ARAUJO FILHO, J. C.; OLIVEIRA, J. B.; CUNHA, T. J. F. **Sistema Brasileiro de Classificação de Solos**. 5. ed. rev. e ampl. Brasília: Embrapa, 2018.

SEGUNDO-URQUIAGA, C.; REICHARDT, K.; LIBARDI, P. L. Efeito do fosfato-de-araxá e superfosfato simples em algumas propriedades físico-químicas e do fósforo residual disponível em um solo Oxic Paleudalf. **Pesquisa Agropecuária Brasileira**, v. 17, n. 2, p. 195-202, 1982.

SFREDO, G. J. Soja no Brasil: **calagem, adubação e nutrição mineral**. Londrina: Embrapa soja, 2008. 145 p. (Embrapa Soja. Documentos, 305).

SHAIBU, A. S.; ADNAN, A. A.; UMAR, I. R. Predicting grain yield of maize using drought tolerance traits. **African Journal of Agricultural Research**, v. 10, n. 33, p. 3332-3337, 2015.

SHARABIAN, V. R.; NOGUCHI, N.; ISHI, K. Significant wavelengths for prediction of winter wheat growth status and grain yield using multivariate analysis. **Engineering in agriculture, environment and food**, v. 7, n. 1, p. 14-21, 2014.

SIBANDA, M.; MUTANGA, O.; ROUGET, M.; ODINDI, J. Exploring the potential of *in situ* hyperspectral data and multivariate techniques in discriminating different fertilizer treatments in grasslands. **Journal of Applied Remote Sensing**, v. 9, n. 1, p. 96-033, 2015.

SILVA, F. C.; ABREU, M. F.; PÉREZ, D. V.; EIRA, P. A.; ABREU, C. A.; RAIJ, B. V.; GIANELLO, C.; COELHO, A. M.; QUAGGIO, J. A.; TEDESCO, M. J.; SILVA, C. A.; BARRETO, W. O. Métodos de análises químicas para avaliação da fertilidade do solo. In: SILVA, F. C. **Manual de análises químicas de solos, plantas e fertilizantes**. 2ª Ed. Brasília: Embrapa Informação Tecnológica, 2009. 627 p.

SILVA JUNIOR, M. C.; PINTO, F. A. C.; QUEIROZ, D. M.; SENA JUNIOR, D. G.; ABRAHÃO, S. A. Utilização de imagens multiespectrais para detectar diferentes níveis nutricionais na forrageira *Brachiaria decumbens*. In: Simpósio Brasileiro de Sensoriamento Remoto. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis: INPE, 2007.

SOCIEDADE BRASILEIRA DE CIÊNCIA DO SOLO. NÚCLEO ESTADUAL PARANÁ. **Manual de adubação e calagem para o Estado do Paraná**. Curitiba: SBCS/NEPAR, 2017. 482 p.

SOUZA, D. R.; VILAR, C. C.; USHIWATA, S. Y.; REIS, R. G. E.; RIBEIRO, K. C. Resposta da cultura do milho, em segunda safra, à adubação fosfatada em Latossolo Amarelo no Cerrado. **Revista de Ciências Agroambientais**, v. 16, n. 1, p. 14-24, 2018.

SOUZA, E. G.; ROCHA, T.; URIBE-OPAZO, M. A.; NÓBREGA, L. H. P. Índices de vegetação no milho em função da hora do dia e da taxa de nitrogênio aplicada. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, p. 865-872, 2009.

SRIPADA, R. P.; HEINIGER, R. W.; WHITE, J. G.; MEIJER A. D. Aerial color infrared photography for determining early in-season nitrogen requirements in corn. **Agronomy Journal**, v. 98, n. 4, p. 968-977, 2006.

STEINER, U.; BÜRLING, K.; OERKE, E. C. Sensorik für einen präzisierten Pflanzenschutz. **Gesunde Pflanzen**, v. 60, n. 4, p. 131-141, 2008.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. 5ª ed. Porto Alegre: Artmed, 2013. 954 p.

TERASHIMA, I.; FUJITA, T.; INOUE, T.; CHOW, W. S.; OGUCHI, R. Green light drives leaf photosynthesis more efficiently than red light in strong white light: Revisiting the enigmatic question of why leaves are green. **Plant and Cell Physiology**, v. 50, n. 4, p. 684–697, 2009.

THENKABAIL, P. S.; ENCLONA, E. A.; ASHTON, M. S.; VAN DER MEER, B. Accuracy assessments of hyperspectral waveband performance for vegetation analysis applications. **Remote sensing of environment**, v. 91, n. 3, p. 354-376, 2004.

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

TUCKER, C. J.; GARRATT, M. W. Leaf optical system modelled as a stochastic process. **Applied Optics**, v. 16, n. 3, p. 635-642, 1977.

VANCE, C. P.; UHDE-STONE, C.; ALLAN, D. L. Phosphorus acquisition and use: critical adaptations by plants for securing a nonrenewable resource. **New Phytologist**, v. 157, n. 3, p. 423–447, 2003.

VARELLA, C. A. A.; PINTO, F. A. C.; COSTA, A. G.; SILVA, T. R. Predição de níveis de nitrogênio aplicados à cultura de milho utilizando imagens digitais. **Revista Engenharia na Agricultura**, v. 27, n. 3, p. 227-236, 2019.

VASCONCELLOS, C. A.; BARBOSA, J. V. A.; SANTOS, H. L. dos; FRANÇA, G. E. de. Acumulação de massa seca e de nutrientes por dois híbridos de milho com e sem irrigação suplementar. **Pesquisa Agropecuária Brasileira**, Brasília, v. 18, n. 8, p. 887-901, 1983.

VENTIMIGLIA, L. A.; COSTA, J. A.; THOMAS, A. L.; PIRES, J. L. F. Potencial de rendimento da soja em razão da disponibilidade de fósforo no solo e dos espaçamentos. **Pesquisa Agropecuaria Brasileira**, Brasília, v. 34, n. 2, p. 195-199, 1999.

VIÑA, A.; GITELSON, A. A.; NGUY-ROBERTSON, A. L.; PENG, Y. Comparison of diferente vegetation indices for the remote assessment of green leaf área index of crops. **Remote Sensing of Environment**, v. 115, n. 12, p. 3468-3478, 2011.

WEBER, V. S.; ARAUS, J. L.; CAIRNS, J. E.; SANCHEZ, C.; MELCHINGER, A. E.; ORSINI, E. Prediction of grain yield using reflectance spectra of canopy and leaves in maize plants grown under different water regimes. **Field Crops Research**, v. 128, n. 1, p. 82-90, 2012.

WILLMOTT, C. J. Some comments on the evaluation of model performance. **Bulletin American Meteorological Society**, v. 63, n. 11, p. 1309–1313, 1982.

WITHAGEN, P. J.; GROEN, F. C. A.; SCHUTTE, K. CCD color camera characterization for image measurements. **IEEE Transactions on Instrumentation and Measurement**, v. 56, n.1, p. 199-203, 2007.

XAVIER, A. C.; RUDORFF, B. F. T.; MOREIRA, M. A.; ALVARENGA, B. S.; FREITAS, J. G.; SALOMON, V. Hyperspectral field reflectance measurements to estimate wheat grain yield and plant height. **Scientia Agricola**, v. 63, n. 2, p. 130-138, 2006.

YANLI, L.; QIANG, L.; SHAOLAN, H.; SHILAI, Y.; XUEFENG, L.; RANGJIN, X.; YONGQIANG, Z.; LIE, D. Prediction of nitrogen and phosphorus contents in citrus leaves based on hyperspectral imaging. **International Journal of Agricultural and Biological Engineering**, v. 8, n. 2, p. 80-88, 2015.

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.

ZHANG, K.; GE, X.; SHEN, P.; LI, W.; LIU, X.; CAO, Q.; ZHU, Y.; CAO, W.; TIAN, Y. Predicting Rice Grain Yield Based on Dynamic Changes in Vegetation Indexes during Early to Mid-Growth Stages. **Remote Sensing**, v. 11, n. 4, p. 387, 2019.

ZHANG, X.; HE, Y. Rapid estimation of seed yield using hyperspectral images of oilseed rape leaves. **Industrial Crops and Products**, v. 42, n. 1, p. 416-420, 2013.

APÊNDICE A

Tabela 20. Teste de normalidade de desvios e homogeneidade de variâncias para os índices de vegetação obtidos em função de diferentes doses do adubo fosfatado MAP, por meio do espectrorradiômetro.

Estádio	Testes	NDVI	GNDVI	RNIR	GNIR	RVI	GRVI
V6	Shapiro-Wilk	0,637 ^{ns}	0,427 ^{ns}	0,516 ^{ns}	0,277 ^{ns}	0,994 ^{ns}	0,809 ^{ns}
	Bartlett	0,405 ^{ns}	0,597 ^{ns}	0,361 ^{ns}	0,540 ^{ns}	0,510 ^{ns}	0,651 ^{ns}
V7	Shapiro-Wilk	0,155 ^{ns}	0,259 ^{ns}	0,107 ^{ns}	0,225 ^{ns}	0,367 ^{ns}	0,363 ^{ns}
	Bartlett	0,371 ^{ns}	0,294 ^{ns}	0,397 ^{ns}	0,342 ^{ns}	0,183 ^{ns}	0,101 ^{ns}
VT	Shapiro-Wilk	0,279 ^{ns}	0,710 ^{ns}	0,329 ^{ns}	0,608 ^{ns}	0,287 ^{ns}	0,968 ^{ns}
	Bartlett	0,684 ^{ns}	0,751 ^{ns}	0,626 ^{ns}	0,698 ^{ns}	0,666 ^{ns}	0,624 ^{ns}
R1	Shapiro-Wilk	0,754 ^{ns}	0,363 ^{ns}	0,788 ^{ns}	0,329 ^{ns}	0,576 ^{ns}	0,195 ^{ns}
	Bartlett	0,825 ^{ns}	0,348 ^{ns}	0,727 ^{ns}	0,223 ^{ns}	0,995 ^{ns}	0,916 ^{ns}
R2	Shapiro-Wilk	0,055 ^{ns}	0,267 ^{ns}	0,075 ^{ns}	0,431 ^{ns}	0,020 [*]	0,052 ^{ns}
	Bartlett	0,850 ^{ns}	0,820 ^{ns}	0,797 ^{ns}	0,720 ^{ns}	0,896 ^{ns}	0,941 ^{ns}
R3	Shapiro-Wilk	0,973 ^{ns}	0,840 ^{ns}	0,973 ^{ns}	0,919 ^{ns}	0,851 ^{ns}	0,646 ^{ns}
	Bartlett	0,180 ^{ns}	0,267 ^{ns}	0,145 ^{ns}	0,202 ^{ns}	0,350 ^{ns}	0,538 ^{ns}
R4	Shapiro-Wilk	0,250 ^{ns}	0,517 ^{ns}	0,276 ^{ns}	0,574 ^{ns}	0,148 ^{ns}	0,274 ^{ns}
	Bartlett	0,701 ^{ns}	0,757 ^{ns}	0,702 ^{ns}	0,753 ^{ns}	0,669 ^{ns}	0,743 ^{ns}
R5	Shapiro-Wilk	0,734 ^{ns}	0,078 ^{ns}	0,721 ^{ns}	0,072 ^{ns}	0,776 ^{ns}	0,105 ^{ns}
	Bartlett	0,255 ^{ns}	0,961 ^{ns}	0,263 ^{ns}	0,960 ^{ns}	0,216 ^{ns}	0,958 ^{ns}

* Significante ao nível de 5% de probabilidade de erro (p-valor < 0,05); ^{ns} Não significativa (p-valor ≥ 0,05).

Tabela 21. Teste de normalidade de desvios e homogeneidade de variâncias para os índices de vegetação obtidos em função de diferentes doses do adubo fosfatado SS, por meio do espectrorradiômetro.

Estádio	Testes	NDVI	GNDVI	RNIR	GNIR	RVI	GRVI
V6	Shapiro-Wilk	0,506 ^{ns}	0,064 ^{ns}	0,423 ^{ns}	0,051 ^{ns}	0,795 ^{ns}	0,318 ^{ns}
	Bartlett	0,922 ^{ns}	0,924 ^{ns}	0,916 ^{ns}	0,879 ^{ns}	0,872 ^{ns}	0,917 ^{ns}
V7	Shapiro-Wilk	0,464 ^{ns}	0,752 ^{ns}	0,458 ^{ns}	0,754 ^{ns}	0,468 ^{ns}	0,594 ^{ns}
	Bartlett	0,814 ^{ns}	0,617 ^{ns}	0,850 ^{ns}	0,657 ^{ns}	0,588 ^{ns}	0,429 ^{ns}
VT	Shapiro-Wilk	0,070 ^{ns}	0,924 ^{ns}	0,090 ^{ns}	0,958 ^{ns}	0,080 ^{ns}	0,881 ^{ns}
	Bartlett	0,928 ^{ns}	0,592 ^{ns}	0,925 ^{ns}	0,542 ^{ns}	0,821 ^{ns}	0,641 ^{ns}
R1	Shapiro-Wilk	0,973 ^{ns}	0,739 ^{ns}	0,948 ^{ns}	0,678 ^{ns}	0,989 ^{ns}	0,834 ^{ns}
	Bartlett	0,252 ^{ns}	0,192 ^{ns}	0,215 ^{ns}	0,156 ^{ns}	0,418 ^{ns}	0,346 ^{ns}
R2	Shapiro-Wilk	0,403 ^{ns}	0,401 ^{ns}	0,400 ^{ns}	0,418 ^{ns}	0,163 ^{ns}	0,093 ^{ns}
	Bartlett	0,259 ^{ns}	0,056 ^{ns}	0,254 ^{ns}	0,055 ^{ns}	0,206 ^{ns}	0,035 [*]
R3	Shapiro-Wilk	0,950 ^{ns}	0,943 ^{ns}	0,942 ^{ns}	0,952 ^{ns}	0,924 ^{ns}	0,984 ^{ns}
	Bartlett	0,403 ^{ns}	0,202 ^{ns}	0,401 ^{ns}	0,184 ^{ns}	0,379 ^{ns}	0,253 ^{ns}
R4	Shapiro-Wilk	0,111 ^{ns}	0,051 ^{ns}	0,122 ^{ns}	0,050 ^{ns}	0,069 ^{ns}	0,023 [*]
	Bartlett	0,463 ^{ns}	0,104 ^{ns}	0,490 ^{ns}	0,112 ^{ns}	0,329 ^{ns}	0,073 ^{ns}
R5	Shapiro-Wilk	0,988 ^{ns}	0,984 ^{ns}	0,988 ^{ns}	0,987 ^{ns}	0,986 ^{ns}	0,901 ^{ns}
	Bartlett	0,254 ^{ns}	0,474 ^{ns}	0,257 ^{ns}	0,463 ^{ns}	0,230 ^{ns}	0,493 ^{ns}

* Significante ao nível de 5% de probabilidade de erro (p-valor < 0,05); ^{ns} Não significante (p-valor ≥ 0,05).

APÊNDICE B

Tabela 22. Teste de normalidade de desvios e homogeneidade de variâncias para os índices de vegetação obtidos em função de diferentes doses do adubo fosfatado MAP, por meio de câmeras digitais.

Estádio	Testes	NDVI	GNDVI	RNIR	GNIR	RVI	GRVI
VT	Shapiro-Wilk	0,389 ^{ns}	0,280 ^{ns}	0,917 ^{ns}	0,317 ^{ns}	0,305 ^{ns}	0,131 ^{ns}
	Bartlett	0,445 ^{ns}	0,040 [*]	0,401 ^{ns}	0,056 ^{ns}	0,187 ^{ns}	0,001 [*]
R1	Shapiro-Wilk	0,877 ^{ns}	0,777 ^{ns}	0,704 ^{ns}	0,887 ^{ns}	0,923 ^{ns}	0,457 ^{ns}
	Bartlett	0,632 ^{ns}	0,730 ^{ns}	0,896 ^{ns}	0,678 ^{ns}	0,563 ^{ns}	0,939 ^{ns}
R2	Shapiro-Wilk	0,987 ^{ns}	0,242 ^{ns}	0,988 ^{ns}	0,294 ^{ns}	0,978 ^{ns}	0,734 ^{ns}
	Bartlett	0,401 ^{ns}	0,603 ^{ns}	0,598 ^{ns}	0,492 ^{ns}	0,289 ^{ns}	0,802 ^{ns}
R3	Shapiro-Wilk	0,730 ^{ns}	0,580 ^{ns}	0,350 ^{ns}	0,382 ^{ns}	0,471 ^{ns}	0,784 ^{ns}
	Bartlett	0,368 ^{ns}	0,177 ^{ns}	0,432 ^{ns}	0,100 ^{ns}	0,192 ^{ns}	0,596 ^{ns}
R4	Shapiro-Wilk	0,224 ^{ns}	0,069 ^{ns}	0,422 ^{ns}	0,070 ^{ns}	0,263 ^{ns}	0,059 ^{ns}
	Bartlett	0,015 [*]	0,837 ^{ns}	0,011 [*]	0,845 ^{ns}	0,016 [*]	0,777 ^{ns}

* Significante ao nível de 5% de probabilidade de erro (p-valor < 0,05); ^{ns} Não significativa (p-valor ≥ 0,05).

Tabela 23. Teste de normalidade de desvios e homogeneidade de variâncias para os índices de vegetação obtidos em função de diferentes doses do adubo fosfatado SS, por meio de câmeras digitais.

Estádio	Testes	NDVI	GNDVI	RNIR	GNIR	RVI	GRVI
VT	Shapiro-Wilk	0,195 ^{ns}	0,823 ^{ns}	0,252 ^{ns}	0,805 ^{ns}	0,193 ^{ns}	0,748 ^{ns}
	Bartlett	0,883 ^{ns}	0,535 ^{ns}	0,784 ^{ns}	0,544 ^{ns}	0,887 ^{ns}	0,382 ^{ns}
R1	Shapiro-Wilk	0,948 ^{ns}	0,866 ^{ns}	0,986 ^{ns}	0,870 ^{ns}	0,927 ^{ns}	0,975 ^{ns}
	Bartlett	0,656 ^{ns}	0,678 ^{ns}	0,562 ^{ns}	0,687 ^{ns}	0,663 ^{ns}	0,586 ^{ns}
R2	Shapiro-Wilk	0,147 ^{ns}	0,232 ^{ns}	0,988 ^{ns}	0,156 ^{ns}	0,122 ^{ns}	0,752 ^{ns}
	Bartlett	0,635 ^{ns}	0,608 ^{ns}	0,499 ^{ns}	0,606 ^{ns}	0,618 ^{ns}	0,501 ^{ns}
R3	Shapiro-Wilk	0,306 ^{ns}	0,503 ^{ns}	0,479 ^{ns}	0,392 ^{ns}	0,210 ^{ns}	0,793 ^{ns}
	Bartlett	0,757 ^{ns}	0,696 ^{ns}	0,257 ^{ns}	0,739 ^{ns}	0,822 ^{ns}	0,378 ^{ns}
R4	Shapiro-Wilk	0,588 ^{ns}	0,179 ^{ns}	0,988 ^{ns}	0,147 ^{ns}	0,383 ^{ns}	0,304 ^{ns}
	Bartlett	0,729 ^{ns}	0,329 ^{ns}	0,550 ^{ns}	0,309 ^{ns}	0,751 ^{ns}	0,356 ^{ns}

* Significante ao nível de 5% de probabilidade de erro (p-valor < 0,05); ^{ns} Não significativa (p-valor ≥ 0,05).