

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

RENATO HERRIG FURLANETTO

Sensores multi e hiperespectrais na identificação e quantificação da deficiência de potássio na cultura do milho (*Zea mays*)

Maringá
2018

RENATO HERRIG FURLANETTO

Sensores multi e hiperspectrais na identificação e quantificação da deficiência de potássio na cultura do milho (*Zea mays*)

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.

Área de concentração: Solos e Nutrição de Plantas.

Orientador: Prof. Dr. Marcos Rafael Nanni.

Maringá
2018

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

F985s

Furlanetto, Renato Herrig

Sensores multi e hiperespectrais na identificação e quantificação da deficiência de potássio na cultura do milho (*Zea mays*) / Renato Herrig Furlanetto. -- Maringá, PR, 2018. 121 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, 2018.

1. Milho (*zea mays*) - cultivo. 2. Inovações - agricultura. 3. Tecnologia - agrícola. 4. Potássio - deficiência nutricional. 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

RENATO HERRIG FURLANETTO

Sensores multi e hiperespectrais na identificação e quantificação da deficiência de potássio na cultura do milho (*Zea mays*)

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 pela Comissão Julgadora composta pelos membros:

COMISSÃO JULGADORA

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

Dr. Adilson de Oliveira Júnior
Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA SOJA)

Prof. Dr. Osvaldo Coelho Pereira Neto
Departamento de Geociências - Universidade Estadual de Londrina (UEL)

Aprovada em: 15 de fevereiro de 2018.

Local de defesa: Sala 4, Bloco J-57, *campus* da Universidade Estadual de Maringá - UEM.

AGRADECIMENTOS

Agradeço ao meu orientador e amigo Marcos Rafael Nanni, que tanto me ajudou com ensinamentos, conselhos e direcionamentos ao longo do mestrado.

A todos os colegas de trabalho do laboratório GALeS, em especial ao Luís Guilherme Teixeira Crusiol pelo companheirismo, ensinamentos e pela enorme ajuda nas coletas de dados para o desenvolvimento do trabalho.

Agradeço à Embrapa Soja, em especial ao Dr. Adilson de Oliveira Júnior, Me. Rubson Sibaldelli e Dr. José Renato Farias por tornar possível a parceria entre as instituições e realizar o acompanhamento e coleta de dados, além da utilização dos laboratórios, dependências e equipe técnica da instituição.

Ao programa de Pós-graduação em Agronomia pela oportunidade de desenvolvimento deste trabalho.

Agradeço ao CNPq, pela concessão de bolsa de estudo durante a realização da Pós-Graduação.

Sensores multi e hiperespectrais na identificação e quantificação da deficiência de potássio na cultura do milho (*Zea mays*)

RESUMO

A utilização de sensores multiespectrais de baixo custo acoplado a VANT's atualmente vem ganhando destaque para identificação e quantificação de diversos problemas nas lavouras como, por exemplo, as deficiências nutricionais. Porém, observa-se, muitas vezes, que a utilização de tais equipamentos não é assistida pela pesquisa científica, necessitando de métodos para a validação desses sensores; caso contrário, podem produzir resultados inconsistentes devido serem populares, de baixo custo e não calibrados radiometricamente. Os sensores hiperespectrais possibilitam aquisição de dados espectrais e identificação de alterações sutis na resposta espectral da vegetação, no qual com o devido processamento, propiciam informações precisas sobre os alvos de interesse. A partir disso, os objetivos deste trabalho foram em investigar o comportamento espectral de plantas de milho submetidas a diferentes condições de disponibilidade de K utilizando o espectrorradiômetro em solo e o sensor imageador hiperespectral AisaFENIX; verificar o potencial de câmeras digitais acoplada ao VANT na identificação da deficiência de K através de índices de vegetação (IV's), comparando-se com os índices obtidos com o uso do espectrorradiômetro; dos IV's significantes, verificou-se a modelagem em regressões lineares para a predição do K foliar. Em outro momento, analisou-se a aplicação de métodos multivariados para a discriminação dos tratamentos a partir de dados do sensor AisaFENIX, bem como a predição de produtividade e K foliar através de regressão multivariada. O experimento metodologicamente foi instalado no delineamento em blocos completos ao acaso (DBC) com 4 blocos e 12 tratamentos, as parcelas experimentais são manejadas de modo que é possível obter diferentes condições de disponibilidade de potássio e fósforo às plantas, obtendo desde condições de severa deficiência até níveis adequados. Foram avaliadas somente as parcelas experimentais cujo efeito foi devido ao K. As avaliações foram realizadas em 03/04 (V3, 10/04 (V5), 17/04 (V7), 24/04 (V8), 03/05 (V10), 08/05 (V12), 26/05 (R1), 16/06 (R3) e 10/07 (R5) com a captura de imagens que cobriram a faixa do visível e infravermelho próximo (350 a 1.000 nm) utilizando-se de duas câmeras digital Fujifilm IS PRO acoplado ao VANT, além das leituras com o espectrorradiômetro. No estágio de desenvolvimento V7 foi realizado o voo com sensor AisaFENIX e realizado coleta para análise de K foliar. Em V12 e

R3 foram realizadas outras coletas para determinação de K foliar. Os dados foram processados com o uso do software QGIS, XLSTAT e Excel, para cálculo dos IV's GNDVI, NDVI, GRVI, GNIR, RNIR e RVI, e SAS e The Unscrambler para os procedimentos multivariados. Os resultados demonstraram que houve alteração no comportamento espectral entre os tratamentos no espectrorradiômetro e no sensor AisaFENIX. Os IV's diferiram significativamente para o tratamento com deficiência em relação ao padrão de adubação, porém, nenhum apresentou sensibilidade para diferenciar o tratamento denominado de "fome oculta". A modelagem em regressões lineares dos IV's apresentou potencial para predição de K, assim como a regressão PLSR a partir dos dados do sensor AisaFENIX para K e produtividade, apresentando boa correlação de Pearson. A análise discriminante foi capaz de separar os tratamentos, obtendo modelos matemáticos passíveis de classificar novos indivíduos com base no espectro de reflectância.

Palavras-chaves: Milho. índices de vegetação. Sensor hiperespectral aerotransportado. VANT. Estatística multivariada.

Multi and hyperspectral sensors in the identification and quantification of potassium deficiency in maize (*Zea mays*)

ABSTRACT

The use of low-cost multispectral sensors coupled with UAV's has been gaining highlight in the identification and quantification of several problems in crops, such as nutritional deficiencies. However, it is often observed that the use of such equipment is not assisted by scientific research, requiring methods for the validation of these sensors, otherwise, they may produce inconsistent results because they are popular, cheap, and not radiometrically calibrated. Hyperspectral sensors allow the acquisition of spectral data and identification of subtle alterations in the spectral response of vegetation, in which, with due processing, provide accurate information about the targets of interest. From this, the objectives of this work were to investigate the spectral behavior of maize plants submitted to different K availability conditions using the spectroradiometer at ground level and the hyperspectral imager sensor AisaFENIX; verify the potential of digital cameras coupled to UAV in the identification of K deficiency through vegetation indices (VI's), comparing with the indices obtained with the use of the spectroradiometer; of the significant VI's, was verified the modeling in linear regressions for the prediction of foliar K. In another moment, the application of multivariate methods for the discrimination of the treatments from AisaFENIX sensor data, as well as the prediction of productivity and foliar K through multivariate regression were analyzed. The experiment was methodologically installed in the complete randomized complete block design with 4 blocks and 12 treatments, the experimental plots are managed so that it is possible to obtain different conditions of availability of potassium and phosphorus to the plants, obtaining from conditions of severe deficiency to appropriate levels. Only experimental plots whose effect was due to K were evaluated. The evaluations were carried out on 03/04 (V3), 10/04 (V5), 17/04 (V7), 24/04 (V8), 03/05 (V10), 08/05 (V12), 26/05 (R1), 16/06 (R3) and 10/07 (R5) with the capture of images that covered the visible and near infrared (350 to 1.000 nm) using two Fujifilm IS PRO digital cameras coupled to the UAV, in addition to the readings with the spectroradiometer at ground level. On April 17, the flight was performed with AisaFENIX sensor and collected leaf for K analysis in laboratory. On V12 and R3 other collected were carried out to determine K leaf. The data were processed using the software QGIS, XLSTAT and Excel, to calculate the

GNDVI, NDVI, GRVI, GNIR, RNIR and RVI VIs, and SAS and The Unscrambler for multivariate procedures. The results showed that there was a change in the spectral behavior between the treatments in the spectroradiometer and the AisaFENIX sensor. The VIs differed significantly for the treatment with deficiency in relation to the standard treatment, but none showed sensitivity to differentiate the treatment called "hidden hunger". The linear regression modeling of the VIs presented potential for K prediction, as well as the PLSR regression from the AisaFENIX sensor data for K and productivity, showing a good Pearson correlation. The discriminant analysis was able to separate the treatments, obtaining mathematical models capable of classifying new individuals based on the reflectance spectrum.

Keywords: Corn. Vegetation Indices. Hyperspectral Airborne Sensor. UAV. Multivariate Statistics.

LISTA DE SIGLAS

ANOVA	–	<i>Análise de variância</i>
ACP	–	<i>Análise de componentes principais</i>
CCD	–	<i>Couple Charge Device</i>
CMOS	–	<i>Complementary Metal Oxide Semiconductor</i>
CONAB	–	<i>Companhia Nacional de Abastecimento</i>
CP's	–	<i>Componentes Principais</i>
DAE	–	<i>Dias após a emergência</i>
EMBRAPA	–	<i>Empresa Brasileira de Pesquisa Agropecuária</i>
GNDVI	–	<i>Índice de Vegetação da Diferença de Verde Normalizado</i>
GNIR	–	<i>Razão entre o verde e o infravermelho próximo</i>
GRVI	–	<i>Razão entre infravermelho próximo e o verde</i>
IAPAR	–	<i>Instituto Agrônômico do Paraná</i>
IV's	–	<i>Índices de vegetação</i>
MCT	–	<i>Mercury Cadmium Telluride</i>
ND	–	<i>Número Digital</i>
NDVI	–	<i>Índice de Vegetação da Diferença Normalizado</i>
PLSR	–	<i>Partial Least Square Regression</i>
REM	–	<i>Radiação eletromagnética</i>
RMSE	–	<i>Root Mean Square Error</i>
RMSEC	–	<i>Root Mean Square Error of Calibration</i>
RMSECV	–	<i>Root Mean Square Error of Cross Validation</i>
RMSEP	–	<i>Root Mean Square Error of Prediction</i>
RNIR	–	<i>Razão entre o vermelho e o infravermelho próximo</i>
RVI	–	<i>Razão entre o infravermelho próximo e vermelho</i>
SAS	–	<i>Statistical Analysis Software</i>
SBCS	–	<i>Sistema Brasileiro de Classificação de Solos</i>
SWIR	–	<i>Short Wave Infrared</i>
USDA	–	<i>United States Department of Agriculture</i>
VANT	–	<i>Veículo aéreo não tripulável</i>
Vis/NIR	–	<i>Visível/Infravermelho Próximo</i>

LISTA DE TABELAS

Tabela 1. Estádios fenológicos de desenvolvimento do milho proposto por Richie e Hanway (1986).	5
Tabela 2. Doses de fósforo e potássio aplicados para os tratamentos estabelecidos.....	27
Tabela 3. Teste de comparação de médias para o teor de K nas datas de avaliações de 17/04 (V7), 08/05 (V12) e 16/06 (R3).....	43
Tabela 4. Teste de normalidade dos erros de Shapiro-Wilk para os índices de vegetação obtido pelo espectrorradiômetro.....	49
Tabela 5. Teste de homogeneidade de variância de Bartlett para os índices de vegetação obtido pelo espectrorradiômetro.....	49
Tabela 6. Teste de comparação de médias dos índices de vegetação obtido pelo espectrorradiômetro, significativo pelo teste F da ANOVA.....	51
Tabela 7. Teste de homogeneidade de variâncias e normalidade dos erros para os índices de vegetação obtido pelo sensor AisaFENIX.....	53
Tabela 8. Teste de comparação de médias dos índices de vegetação obtido pelo sensor AisaFENIX.....	53
Tabela 9. Teste de homogeneidade de variâncias e normalidade dos erros para os índices de vegetação obtido por câmeras digitais acopladas ao VANT.	55
Tabela 10. Teste de homogeneidade de variância de Bartlett para os índices de vegetação obtido pelo espectrorradiômetro.....	56
Tabela 11. Teste de comparação de médias dos índices de vegetação obtido por câmeras digitais acopladas ao VANT.....	58
Tabela 12. Seleção de bandas espectrais para participação na construção dos modelos discriminantes lineares a partir de dados do sensor hiperespectral AisaFENIX.	64

Tabela 13. Coeficientes dos modelos discriminantes lineares.....	66
Tabela 14. Quadrado da distância generalizada entre as médias dos tratamentos.....	67
Tabela 15. Resumo da ressubstituição usando a função discriminante linear.	68
Tabela 16. Estimativa do erro para cada tratamento reclassificado pela análise discriminante.	68
Tabela 17. Resultados obtidos por meio da análise discriminante simulada com dados usados no modelo (60%).	69
Tabela 18. Resultados obtidos por meio da análise discriminante simulada com dados usados no modelo (40%).	71
Tabela 19. Modelos de regressões lineares para estimativa de K foliar utilizando os IV's obtidos por câmeras digitais acopladas ao VANT.	74
Tabela 20. Estimativa do K foliar em g kg^{-1} por meio dos IV's obtidos por câmeras digitais acopladas ao VANT nos estádios de desenvolvimento V7, V12 e R3.....	76
Tabela 21. Parâmetros estatísticos do modelo PLSR para estimação da produtividade em milho.....	81
Tabela 22. Valores de referência da produtividade e os valores estimados pelo modelo PLS (em kg ha^{-1}).....	82
Tabela 23. Parâmetros estatísticos do modelo PLSR para estimativa do teor de K foliar em milho.....	84
Tabela 24. Valores de referência do teor de K e os valores estimados pelo modelo PLSR (em g kg^{-1}).....	87
Tabela 25. Características químicas do solo no ano de 2015 das parcelas experimentais referente aos tratamentos estudados.	103

LISTA DE FIGURAS

Figura 1 - Plantas de milho com sintomas visíveis de deficiência de K.	9
Figura 2 - Diferenças no desenvolvimento das plantas de milho entre as parcelas experimentais submetidos a doses diferentes de adubação potássica. Parcela esquerda refere-se aos tratamentos T-12 (130 kg ha ⁻¹ KCL), parcela a direita tratamento T-3 (50 kg ha ⁻¹ KCL).	10
Figura 3 - Interação da REM proveniente do sol com a vegetação e seu respectivo comportamento espectral, onde (A) energia absorvida, (B) refletida e (C) transmitida.	13
Figura 4 - Diferenças entre o sistema multiespectral obtido por câmeras digitais (A) e o sistema imageador hiperespectral (B).....	17
Figura 5 - Esquerda - Ilustração da variância explicada (eixo y) pelas CP's (eixo x). Direita – variância acumulada (eixo y - V CUMUL) pelo número CP's utilizada (eixo x).....	22
Figura 6 – Fluxograma do processo metodológico utilizado no experimento.	25
Figura 7 - VANT octocóptero utilizado durante o período das avaliações.	29
Figura 8 - ASD Plant Probe com a folha climpada para obter a leitura espectral das plantas de milho no experimento utilizando o espectrorradiômetro ASD Fieldspec 3 Jr.	32
Figura 9 - Representação dos equipamentos para obtenção da imagem hiperespectral a partir do sensor AisaFENIX.....	37
Figura 10 - Fator de reflectância médio das folhas de milho nos diferentes estádios de desenvolvimento avaliado.	45
Figura 11 - Folhas de milho com coloração amarelada, possivelmente, decorrente da redução da concentração de clorofila nas folhas.....	47
Figura 12 - Distribuição das curvas espectrais obtidas pelo sensor hiperespectral AisaFENIX nos tratamentos T-2, T-6 e T-12.....	59

Figura 13 – Leitura espectral da folha do milho com o ASD Plant Probe.	61
Figura 14 - Dispersão dos scores da primeira e segunda componentes principais referentes aos tratamentos T-2, T-6 e T-12.	63
Figura 15 - Resultado do “Leverage” para identificação de possíveis “Outliers” e dispersão das amostras e limite (elipse) de T^2 Hotelling's para identificação de possíveis “Outliers”. ...	78
Figura 16 - RMSE da validação cruzada (linha vermelha) e da calibração (linha azul) para escolha do número de fatores ideais para construção do modelo PLSR.	79
Figura 17 - Dispersão da calibração (linha azul) e calibração cruzada (linha vermelha) versus os dados de referência da produtividade. A linha preta representa a reta 1:1.	80
Figura 18 - Coeficientes de regressão do modelo PLSR para predição da produtividade do milho.	82
Figura 19 - Coeficientes de regressão do modelo PLSR para predição de K foliar em milho.	86

SUMÁRIO

1. INTRODUÇÃO	1
2. OBJETIVOS	3
2.1. Objetivo geral	3
2.2. Objetivos Específicos	3
3. REVISÃO DE LITERATURA	4
3.1. A cultura do milho.....	4
3.1.1. Características da planta de milho	4
3.1.2. Importância econômica	6
3.1.3. Potássio na cultura do milho.....	6
3.1.4. Funções e sintomas de deficiência.....	8
3.2. Sensoriamento remoto aplicado no estudo de culturas agrícolas	10
3.2.1. Princípio	10
3.2.2. Comportamento espectral da vegetação.....	11
3.2.3. Níveis de aquisição de dados.....	13
3.2.4. Radiância e reflectância	13
3.2.5. Tipos de sensores	14
3.2.6. Sensor imageador multiespectral	14
3.2.7. Sensor imageador e não imageador hiperespectral.....	16
3.3. Utilização de VANT's para o monitoramento remoto de culturas agrícolas	17
3.4. Processamento de imagens.....	19
3.5. Índices de vegetação.....	20
3.6. Estatística multivariada – modelos de regressões pelo método dos mínimos quadrados parciais (PLSR).....	21
4. MATERIAL E MÉTODOS	25
4.1. Caracterização, localização geográfica da área de estudo e implantação do experimento	26
4.2. Obtenção das imagens aéreas por VANT.....	28
4.3. Processamento das imagens obtidas por VANT	30
4.4. Obtenção de dados espectrorradiométricos das plantas em nível de terrestre	31
4.5. Obtenção dos índices de vegetação pelo espectrorradiômetro, câmeras digitais e sensor imageador hiperespectral aerotransportado AisaFENIX	33
4.6. Datas de avaliações ao longo do ciclo de cultura.....	35
4.7. Análise foliar	35
4.8. Imageamento com sensor hiperespectral aerotransportado.....	36

4.9.	Análise dos dados.....	38
4.9.1.	Análise estatística multivariada dos dados hiperespectrais obtido pelo sensor Aisa FENIX	39
5.	RESULTADOS E DISCUSSÕES	43
5.1.	Teste de comparação de médias para o teor de potássio foliar em milho	43
5.2.	Comportamento espectral das plantas de milho em resposta aos níveis de K ⁺ no solo	44
5.3.	Avaliação da relação entre índices de vegetação obtidos por meio do espectrorradiômetro, câmeras digitais e o sensor AisaFENIX, com os tratamentos estudados	48
5.3.1.	Índices de vegetação obtido pelo espectrorradiômetro a nível de folha	48
5.3.2.	Índices de vegetação obtido pelo sensor imageador hiperespectral AisaFENIX	52
5.3.3.	Índices de vegetação obtido por câmeras digitais.....	53
5.4.	Comportamento espectral obtido pelo sensor imageador hiperespectral AisaFENIX.....	59
5.5.	Análise de componentes principais (ACP) a partir de dados de reflectância obtido pelo sensor imageador hiperespectral AisaFENIX	62
5.6.	Funções discriminantes a partir da curva espectral obtida pelo sensor imageador hiperespectral Aisa FENIX	64
5.7.	Modelos de regressões lineares para predição do teor potássio foliar utilizando os índices de vegetação obtidos por câmeras digitais acopladas ao VANT	73
5.8.	Modelo de predição para produtividade utilizando a regressão por quadrados mínimos parciais (PLSR) a partir dos dados do sensor imageador hiperespectral AisaFENIX.....	78
5.9.	Modelo de predição do teor potássio foliar utilizando a regressão por quadrados mínimos parciais (PLSR) a partir dos dados do sensor imageador hiperespectral AisaFENIX.....	84
6.	CONCLUSÃO	88
7.	REFERÊNCIAS BIBLIOGRÁFICAS	89
	APÊNDICE A	103
	APÊNDICE B.....	104

1. INTRODUÇÃO

O Brasil situa-se entre os maiores produtores mundiais de milho, atrás apenas dos Estados Unidos e China (USDA). Apesar do alto potencial produtivo deste cereal observa-se na prática, limitação no aumento da sua produtividade decorrente de diversos fatores. Dentre eles, destacam-se os baixos níveis de nutrientes nos solos e o uso inadequado dos fertilizantes, como sendo as principais causas limitantes. Aliado a isso, a planta de milho é vista como exigente em fertilidade, sendo considerada altamente responsiva.

Entre todos os elementos essenciais ao desenvolvimento da planta de milho, o íon potássio (K) é considerado um dos mais abundante no citoplasma e o segundo elemento absorvido em maiores quantidades. Interage com vários outros importantes nutrientes, beneficiando a absorção e redistribuição destes, mas também pode agir negativamente através da competição pela absorção nas raízes e translocação pelas membranas celulares.

A importância metabólica do K na planta é devido à participação em inúmeros processos bioquímicos, atuando na síntese e no metabolismo de carboidratos, na fotossíntese e na respiração. Atua na formação de compostos nitrogenados, como as proteínas, síntese, translocação, armazenamento de açúcares e aumenta a absorção e transporte de Fe^{2+} nas células, entre outros importantes processos.

O aparecimento dos sintomas visíveis de deficiência, é caracterizado como o último passo de uma série de problemas metabólicos de carácter irreversível, onde a produção será extremamente comprometida. Por outro lado, nem sempre os sintomas de deficiência nutricional são visíveis embora, provavelmente, os efeitos prejudiciais sejam notáveis na produtividade. A planta, durante o crescimento vegetativo, não exhibe características anormais, dificultando o processo de identificação desta deficiência conhecida como “fome oculta” e a realização da correção da adubação a níveis adequados para a planta.

Devido à dificuldade de identificação, há necessidade em buscar métodos rápidos e precisos para a caracterização da mesma e, também, a quantificação do nutriente na folha, visando complementar as análises laboratoriais que são geralmente de intensa mão de obra e procedimentos considerados demorados, além de apresentarem preços relativamente elevado. Há, também, o risco de contaminação ambiental devido a utilização de reagentes químicos para a realização das análises.

Com a evolução na tecnologia de sensores, da redução de seus custos de produção e facilidade de aquisição, o monitoramento de grandes áreas agrícolas, o que antes era

impraticável, devido aos custos e tempo de realização, atualmente é possível serem realizados em poucas horas produzindo resultados satisfatórios, com a utilização de sensores multiespectrais e hiperespectrais aerotransportados ou acoplados à VANT's (Veículo Aéreo Não Tripulável).

Entre os diversos sensores multiespectrais disponíveis, a utilização de câmeras fotográficas digitais modificadas de baixo custo tem-se tornado uma das principais ferramentas na agricultura moderna. Sendo aplicadas na identificação de problemas nas lavouras e, até mesmo, na quantificação da produtividade, biomassa, deficiências, nutrientes, entre outros.

Observa-se, portanto, o aumento expressivo na utilização de tais equipamentos. Porém, constata-se na prática, que a pesquisa científica não acompanha esta demanda, conseqüentemente, não há metodologias para utilização destes equipamentos, necessitando da certificação de métodos para a utilização correta dos mesmos.

Além disso, muitas vezes, não é possível a identificação de problemas e/ou quantificação por meio de produtos de sensoriamento remoto como, por exemplo, os índices de vegetação (IV's), pois estes sensores operam em poucas bandas do espectro eletromagnético, além de serem bandas largas, podendo ocultar informações importantes e dificultar o processo de interpretação. Surge, portanto, a necessidade de utilização de sensores que apresentam maior sensibilidade em detectar alterações nas vegetações.

Estes equipamentos, conhecidos como sensores hiperespectrais, operam em centenas de bandas espectrais contíguas e estreitas, com altíssima resolução espectral, oferecendo grande potencial para melhorar a avaliação, identificação e classificação de problemas na agricultura, pois é possível o conhecimento da "assinatura espectral" da vegetação e identificação de alterações "sutis" no espectro de reflectância devido a influência de fatores, como, por exemplo, a(s) deficiência(s) nutricional(is). Uma vez identificado, podem ser classificadas, diferenciadas e modeladas, produzindo resultados mais confiáveis e precisos.

Neste contexto, a hipótese apresentada neste trabalho é se a utilização de câmeras fotográficas digitais acopladas ao VANT, o sensor hiperespectral em solo e o sensor imageador hiperespectral AisaFENIX aerotransportado, possuem a capacidade de identificação, discriminação e quantificação da deficiência de K na cultura do milho, através de produtos do sensoriamento remoto e técnicas estatísticas avançadas, comparando com procedimentos laboratoriais padrão de análise deste nutriente e verificando a possível substituição por métodos mais rápidos e menos onerosos através de sensores remotos.

2. OBJETIVOS

2.1. Objetivo geral

O desenvolvimento do presente trabalho buscou avaliar e caracterizar o comportamento espectral de plantas de milho submetidas a diferentes teores de potássio (K) no solo, utilizando de sensores espectrais terrestre e aéreo.

2.2. Objetivos Específicos

Os objetivos específicos que orientaram a pesquisa foram:

- Analisar, estatisticamente, índices de vegetação extraídos de imagens obtidas por câmeras fotográficas digitais acopladas em VANT, espectrorradiômetro em solo e o sensor imageador AisaFENIX na identificação da deficiência de K nas plantas;
- Obter modelos matemáticos-estatísticos para predição de K foliar nas plantas, a partir de dados hiperespectrais do sensor imageador AisaFENIX e dos índices de vegetação obtido por câmeras fotográficas digitais;
- Obter modelo matemático-estatístico para predição da produtividade a partir de dados hiperespectrais do sensor imageador AisaFENIX;
- Obter modelos discriminantes para identificação das diferentes condições de disponibilidade de K nas parcelas experimentais, e;
- Avaliar o comportamento espectral em função dos teores de K^+ no solo.

3. REVISÃO DE LITERATURA

3.1. A cultura do milho

3.1.1. Características da planta de milho

O milho é uma planta taxonomicamente classificada como *Zea mays* L. subsp. *mays* pertencente à família Poaceae (MACHADO et al., 1998; PATERNIANI e CAMPOS, 1999), trata-se umas das espécies vegetais mais estudadas no mundo. A idade estimada do milho é de aproximadamente 11 milhões de anos sendo classificado como de origem mesoamericana com gênese no México. Devido a sua grande adaptabilidade e a ampla variedade de genótipos, as áreas de cultivos estendem-se desde a latitude de 58° Norte até 40° Sul. Encontrando-se, assim, em climas tropicais, subtropicais e temperados (MONTEIRO et al., 2009).

As características de cultivo mais propícias ao desenvolvimento da planta de milho são em regiões cuja precipitação varia entre 300 a 5.000 mm anuais, com boa distribuição nos períodos mais críticos de seu desenvolvimento, sendo a quantidade de água consumida por uma planta em média de 600 mm/ciclo (ALDRICH et al., 1982). A temperatura ideal de desenvolvimento situa-se entre 25°C a 30°C. Sendo que, temperatura abaixo de 10°C, o crescimento é praticamente nulo e, em temperaturas superiores a 40°C, é prejudicial à cultura, causando perda do rendimento de grãos (MONTEIRO et al., 2009). O grande interesse no cultivo deste cereal é devido, principalmente, as suas qualidades nutricionais, sendo utilizado na alimentação humana, animal e no setor energético.

O desenvolvimento da planta de milho, assim como de outras espécies vegetais, apresenta comportamento específico e progressivo. Sendo assim, para facilitar o manejo e os tratamentos culturais é necessário a identificação dos estádios de desenvolvimento, pois facilita a compreensão das diferentes demandas nutricionais, hídricas e fitossanitárias durante o período de crescimento da planta.

Existem dois sistemas propostos para a divisão do estágio de desenvolvimento da planta de milho. O sistema proposto por Richie e Hanway (1989) e o sistema proposto por Fancelli (1986), no presente trabalho será utilizado o sistema de Richie e Hanway, apresentado na Tabela 1.

Neste sistema, os estádios de desenvolvimento são divididos em vegetativo (V) e reprodutivo (R), sendo o vegetativo subdivididos numericamente (V1, V2, ... , Vn) de acordo

com a folha de inserção mais alta cuja aurícula seja visível. O primeiro e último estágio vegetativo são designados como VE (emergência) e VT (pendoamento), e o estágio reprodutivo subdividido com base no desenvolvimento do grão, sendo denominados como R1 (florescimento), R2 (grão leitoso), R3 (grão pastoso), R4 (grão farináceo), R5 (grão farináceo-duro) e R6 (maturidade fisiológica).

Tabela 1. Estádios fenológicos de desenvolvimento do milho proposto por Richie e Hanway (1986).

Estádio de desenvolvimento	Descrição fenológica
ESTÁDIOS VEGETATIVOS (V)	
VE	Emergência
V1	Primeira folha totalmente expandida
V2	Segunda folha totalmente expandida
V3	Terceira folha totalmente expandida
V6	Sexta folha totalmente expandida
V9	Nona folha totalmente expandida
V(n)	Enésima folha totalmente expandida
VT	Pendoamento
ESTÁDIOS REPRODUTIVOS (R)	
R1	Florescimento
R2	Grão leitoso
R3	Grão pastoso
R4	Grão farináceo
R5	Grão farináceo-duro
R6	Maturidade fisiológica

Fonte: Adaptado de Richie e Hanway (1986).

Variações no padrão de desenvolvimento podem ocorrer devido a fatores como o clima, temperatura, precipitação, data de plantio, genótipo, fertilidade do solo, entre outros. Essas variações influenciam, principalmente, no tempo de duração entre os estádios de desenvolvimento e no número total de folhas, podendo ocasionar perda na produtividade e, conseqüentemente, menor valor na comercialização do produto colhido.

3.1.2. Importância econômica

O Brasil situa-se entre os maiores produtores mundiais de milho atrás apenas dos Estados Unidos e China, correspondendo a 8,1% da produção mundial deste cereal (USDA). No âmbito nacional encontram-se os estados do Mato Grosso, Paraná e Mato Grosso do Sul como sendo os maiores produtores nacionais desta cultura (primeira safra e segunda safra). De acordo com a CONAB (2017) a área plantada na safra de 2016/2017 correspondeu ao total de 17,591 milhões de hectares, sendo a percentagem da produção total por produto de 35,93% ocupado pelo milho.

Ainda segundo a CONAB (2017) a produtividade do milho apresentou recuperação em relação à última safra, com produtividade de aproximadamente 5.560 kg ha⁻¹ (primeira e segunda safra). Já a produção total foi entorno de 97,817 milhões de toneladas, distribuídas entre primeira safra (33,03 milhões de toneladas) e segunda safra (64,78 milhões de toneladas).

Diferentemente de outras culturas, como exemplo a soja, que possui commodities processadas como o farelo de soja e o óleo de soja, o milho é essencialmente destinado ao comércio em sua forma “*in natura*”, em grande maioria para o consumo animal, visto sua excelente qualidade nutricional e energética, compondo como principal ingrediente nas rações utilizadas na alimentação de aves, bovinos, peixes e suínos, representando de 60 a 80% do total do produto. Outra parte da produção é destinada à exportação, movimentando no ano de 2017, aproximadamente US\$ 4,036 bilhões, sendo os principais destinos a China, Irã, Egito, Vietnã, Israel, Malásia e Coreia do Sul (Confederação da Agricultura e Pecuária do Brasil - CNA).

No que diz respeito a participação no PIB do país, de acordo com a CNA (2017), o agronegócio contribui com 23,5% no ano de 2017, decorrente da safra recorde favorecido pelas ótimas condições climáticas ao desenvolvimento das plantas, destacando a cultura do milho primeira e segunda safra.

3.1.3. Potássio na cultura do milho

Com o rápido crescimento da população mundial, a pressão pela demanda na produção de alimentos tem aumentado de forma significativa. Dentre todos os fatores limitantes no aumento da produtividade das culturas, o manejo nutricional tem-se tornado uma das maiores preocupações na produção mundial, visto que os solos são manejados

inadequadamente, naturalmente de baixa fertilidade e, muitas vezes, realizadas adubações de maneira inadequada o que tem contribuído para o surgimento de graves danos ambientais. Até o momento são relatados danos na América do Norte, China e Europa, e, especialmente, em regiões mais pobres do mundo (GRUHN et al., 2000; CHEN et al., 2011).

Atualmente, a deficiência nutricional de K tem-se tornado cada vez mais presente nas propriedades rurais, comprometendo seriamente a produção caso não seja corrigido no momento adequado. A deficiência de K é mais frequente em solos de textura mais arenosas e em regiões que apresentam elevadas precipitações, onde é lixiviado para camadas mais profundas do solo tornando-se, em certas condições, inacessíveis às plantas. Além disso, solos com longo histórico de cultivo e exaurido em nutrientes também são passíveis de provocar deficiência nas plantas. A correção da deficiência de K no solo pode ser através da adubação com fertilizantes que apresentam em sua constituição o íon K. Os fertilizantes mais utilizados são o cloreto de potássio, o sulfato de potássio, o fosfato de potássio e o nitrato de potássio.

O milho é uma planta altamente exigente e responsiva aos nutrientes, necessitando manter a disponibilidade dos mesmos, de forma equilibrada, durante o ciclo de desenvolvimento. Entre todos os nutrientes essenciais para o crescimento e desenvolvimento da planta de milho, o íon K é o nutriente mais abundante e o segundo elemento absorvido em maiores quantidades pela planta quando comparado com outros elementos. Alguns pesquisadores relatam que a absorção de K é relativamente lenta durante as primeiras semanas após a germinação, ocorrendo considerável aumento e mantendo a uma taxa constante de demanda conforme a planta vai desenvolvendo-se (GAMBOA, 1980). Outros pesquisadores relataram que a absorção de K pelas plantas de milho foi de 86% até o estágio de florescimento (KARLEN et al., 1988), acumulando mais em relação ao nitrogênio e fósforo nos estádios iniciais (HANWAY, 1962; SAYRE, 1948).

Segundo Stipp e Yamada (1988), a absorção de K pelas plantas de milho é mais intensa no período que antecede o “embonecamento”, sendo que 70% do K requerido pelas plantas é absorvida neste período. Porém, a absorção de nutrientes até o final do ciclo da planta é importante para compensar as perdas excessivas que ocorrem nas folhas pela translocação dos mesmos para os grãos.

Coelho e Alves (2004) observaram que a absorção de K é máxima durante o estágio vegetativo, com elevada taxa de acúmulo nos primeiros 30 a 40 dias de desenvolvimento, o que sugere que o nutriente deve estar disponível para as plantas na fase inicial de desenvolvimento.

Dentre o total absorvido, o K apresenta menor taxa de exportação para os grãos em relação ao N e P, com valores que variam entre 26 a 43% (FERNANDES et al., 1998). Com relação à mobilidade, é considerado o mais móvel dos nutrientes no sistema solo-planta-atmosfera e, particularmente, na planta. A movimentação na planta é facilitada devido à presença em maior proporção na forma iônica nos tecidos, diferentemente dos outros nutrientes; aliado a isso, por apresentar elevada solubilidade, o K facilmente movimenta-se através das membranas celulares com movimentos nos dois sentidos, ou seja, influxo e efluxo.

3.1.4. Funções e sintomas de deficiência

A importância metabólica do K na planta é devido a participação em inúmeros processos bioquímicos, atuando na síntese e no metabolismo de carboidratos, como a fotossíntese e a respiração, embora não seja integrante em nenhum composto dentro da planta (MALAVOLTA e CROCOMO, 1982). Participa na formação de compostos nitrogenados, como as proteínas, síntese, translocação e armazenamento de açúcares, aumenta a absorção e transporte de Fe^{2+} nas células. É requerido na ativação de no mínimo 60 diferentes enzimas envolvidas no crescimento da planta, principalmente do grupo das sintetases, oxidorreduções, desidrogenases e quinases, relacionadas com os processos de assimilação de CO_2 e nitrogênio (BULL e CANTARELLA, 1993; FAGERIA e GHEYI, 1999).

Por atuar na assimilação do CO_2 , o K proporciona melhor eficiência na utilização da luz, aumentando a taxa fotossintética da planta devido ao aumento da área foliar, além de ajudar na translocação de açúcares para outros órgãos da planta.

Outra importante característica deste nutriente é na regulação osmótica, atuando diretamente no mecanismo de fechamento e abertura dos estômatos, melhorando significativamente a eficiência dos processos bioquímicos que envolvem a utilização da água pela planta. Além disso, teor adequado do nutriente na planta está relacionado com a resistência a doenças (HUBER e ARNY, 1985), menor acamamento (BULL e CANTARELLA, 1993), tolerância a estresses por umidade e à baixa temperatura (MENGEL e KIRKBY, 1987).

Embora o íon K não seja constituinte de clorofilas, a falta deste elemento promove a destruição das mesmas, indicando que ocorre a participação do K como precursor na formação de clorofila e/ou prevenindo a decomposição (FAGERIA e GHEYI, 1999).

Quando o fornecimento de K para as plantas está em níveis inferiores à necessidade da mesma, ocorre a limitação no crescimento e desenvolvimento, comprometendo seriamente a produção. O primeiro sintoma visível de deficiência de K na planta é marcado pela clorose marginal das folhas mais velhas, evoluindo para necrose e dilaceração do tecido (ROBERTS, 2005), devido ao acúmulo de compostos nitrogenados solúveis, como as aminas, putrescinas e agmatina (Figura 1) (VASCONCELOS et al., 1983). Colmos com internódios mais curtos do que o normal, clorose internerval nas folhas mais novas e acamamento, por falta de estrutura celular, são outros sintomas característicos da deficiência deste elemento (Figura 1 e 2).



Figura 1 - Plantas de milho com sintomas visíveis de deficiência de K.

Tal fato vale ressaltar que, nos estádios finais de desenvolvimento da planta, quando ocorre o aparecimento dos sintomas visíveis de deficiência, é caracterizado como o último passo de uma série de problemas metabólicos de carácter irreversível, onde a produção será extremamente comprometida. Por outro lado, nem sempre os sintomas de deficiência nutricional são visíveis, ou seja, a planta durante o crescimento vegetativo não exhibe características anormais de crescimento, dificultando o processo de identificação e a realização da correção da adubação a níveis adequados para a planta. Esta deficiência é conhecida como “fome oculta”, e ocorre quando a carência é “leve”, porém influenciará na perda de produtividade.

Devido à dificuldade de identificação dos sintomas de deficiência de maneira precoce há necessidade em buscar métodos rápidos e precisos para a sua caracterização com o objetivo de estabelecer o manejo adequado de fertilizantes que possa recuperar e/ou minimizar as perdas causadas, além de complementar e/ou substituir as análises laboratoriais para determinar a concentração foliar deste elemento, onde são considerados procedimentos

geralmente de intensa mão de obra, demorado e de preços relativamente elevado. Há também o risco de contaminação ambiental devido a utilização de reagentes químicos para a realização das análises.



Figura 2 - Diferenças no desenvolvimento das plantas de milho entre as parcelas experimentais submetidas a doses diferentes de adubação potássica. Parcela esquerda refere-se aos tratamentos T-12 ($130 \text{ kg ha}^{-1} \text{ KCL}$), parcela a direita tratamento T-3 ($50 \text{ kg ha}^{-1} \text{ KCL}$).

3.2. Sensoriamento remoto aplicado no estudo de culturas agrícolas

3.2.1. Princípio

O sensoriamento remoto pode ser definido como uma parte da ciência na qual se adquire informações sobre objetos sem que haja contato físico com os mesmos (LILLESAND e KIEFER, 1994). Utiliza-se de sensores de forma conjunta e, equipamentos para o processamento de dados com a finalidade de estudar, de forma analítica, as interações entre a energia eletromagnética (REM) e as diversas coberturas vegetais que compõem o globo terrestre (NOVO, 2010). É baseado no princípio que cada alvo na superfície terrestre apresenta uma característica distinta e específica quando ocorre a interação da REM com os mesmos. Esta energia é carregada pelo espaço através de ondas eletromagnéticas de diferentes comprimentos de ondas, variando desde uma fração de nanômetro até vários metros, sendo que, para cada um desses comprimentos de onda existe um comportamento espectral específico do alvo de interesse (FONSECA e FERNANDES, 2004).

Quanto menor o comprimento de onda, maior é sua frequência e maior a sua energia. Toda REM que incide sobre a vegetação é fracionada em três partes, ou seja, absorvida, transmitida e refletida. Os sensores captam uma fração desta energia (fótons) após a interação

com os alvos, permitindo a aquisição de grandezas denominadas de absorvância, transmitância e reflectância (MOREIRA, 2011), convertendo em dados passíveis de interpretação.

A magnitude de cada uma dessas partes depende da região do espectro eletromagnético e a interação com o alvo em estudo. No estudo da vegetação utilizam-se valores de reflectância que são obtidos por meio da razão do fluxo de REM emitida pela vegetação, conhecida como radiância, pelo fluxo de REM emitido por uma superfície padrão de referência (MOREIRA, 2011).

3.2.2. Comportamento espectral da vegetação

O sensoriamento remoto quando aplicado ao estudo agrícola é estabelecido um intervalo de comprimento de onda que vai de 350 nm a 2.500 nm, dentre todo o espectro eletromagnético existente, pois este intervalo está associado com as interações da REM com as estruturas celulares vegetais (JENSEN, 2009), representados pela interação com os fotossistemas, pigmentos, estrutura foliar, quantidade de água presente na folha, entre outros constituintes da planta. As quantidades de REM absorvida, transmitida e refletida pelas folhas das plantas podem diferir de uma espécie para outra ou até mesmo dentro da própria espécie, pois existem os fatores abióticos e bióticos que influenciam direta ou indiretamente nesta interação (MOREIRA, 2011, GATES et al., 1965), como exemplo as alterações no crescimento e no metabolismo das plantas submetidas às condições de deficiências.

Cerca de 50% do total da REM que chega até a planta é absorvida pelos pigmentos contidos no mesófilo das folhas, compreendendo a região do visível (400 a 700 nm). Nesta faixa espectral, tanto a reflectância quanto a transmitância são menores do que 15%, sendo que a reflectância apresenta um pico máximo em comprimento de onda próximo de 530 nm do espectro eletromagnético referente à região verde do espectro (MOREIRA, 2011).

No mesófilo os pigmentos estão divididos em clorofilas (65%), carotenos (6%), xantofilas (29%) e antocianinas. Nele a REM absorvida pelas folhas é espalhada em virtude das interações da radiação com as paredes celulares hidratadas, o que origina múltiplas reflexões e refrações, propiciando melhor absorção da radiação pelos pigmentos (KNIPLING, 1970). Devido às características dos mesmos, a absorção máxima da REM é maior no comprimento de onda de 453 a 643 nm para clorofila “b” e de 430 a 660 nm para clorofila “a”, α - Caroteno de 420, 440 e 470 nm, β - Caroteno de 425, 450 e 480 nm, xantofilas, luteol 425, 445 e 475 nm, violoxanto 425, 450 e 475 nm (ASSUNÇÃO e FORMAGGIO, 1989,

MOREIRA, 2011). Essa energia participa na síntese de compostos ricos em energia (fotossíntese), altera estruturas moleculares (fotoconversão), acelera reações, como a fotoxidação das xantofilas ou ainda destrói estruturas de uma molécula devido à formação de espécies oxidativas de oxigênio.

Na região do infravermelho próximo (700 a 1.300 nm), o comportamento da REM quanto à reflexão, transmissão e absorção é denominado pelas propriedades ópticas da folha. Existe pequena absorção e considerável espalhamento interno que dependem das estruturas celulares do mesófilo. Nessa região espectral, a absorção é muito baixa (menos de 15%) e a reflectância pode chegar até 50% (TUCKER e GARRATT, 1977). De modo geral, quanto mais lacunosa for à estrutura interna foliar, maior será o espalhamento interno da radiação incidente e, conseqüentemente, maior será também a reflectância.

A região do infravermelho médio (1.300 a 3.000 nm) caracteriza-se pelo decréscimo da reflectância da vegetação, em razão da quantidade de água líquida presente na folha. A água absorve nos comprimentos de onda de 1.400, 1.900 e 2.500 nm. Com isso, quanto maior a presença de água na folha, menor será a reflectância nessa faixa do espectro eletromagnético.

A vegetação sadia apresenta resposta espectral característica em todo o espectro eletromagnético (Figura 3), com menor reflectância na região do vermelho (próximo a 630 nm) e azul (próximo a 430 nm) e um pico de reflectância característico na região do comprimento de onda do verde (próximo a 530 nm), resultante da absorção da energia pelos pigmentos constituintes das plantas.

Já na região do infravermelho próximo, ocorre aumento da reflectância que inicia próximo a 700 nm, proporcionado pela interação da REM com a estrutura do mesófilo das folhas, apresentando feições de absorção devido à interação com moléculas d'água próximo a 1.400 e 1.900 nm.

Quando as plantas sofrem algum tipo de estresse, ocorre uma série de alterações bioquímicas em resposta a condição submetida, resultando em alterações em toda a curva espectral da planta, devido à diminuição da atividade fotossintética, fechamento estomático, presença de metabólitos secundários, regiões de clorose, necrose, desfolha precoce, entre outras importantes alterações, sendo, portanto, passíveis de mensurações através de técnicas do sensoriamento remoto.

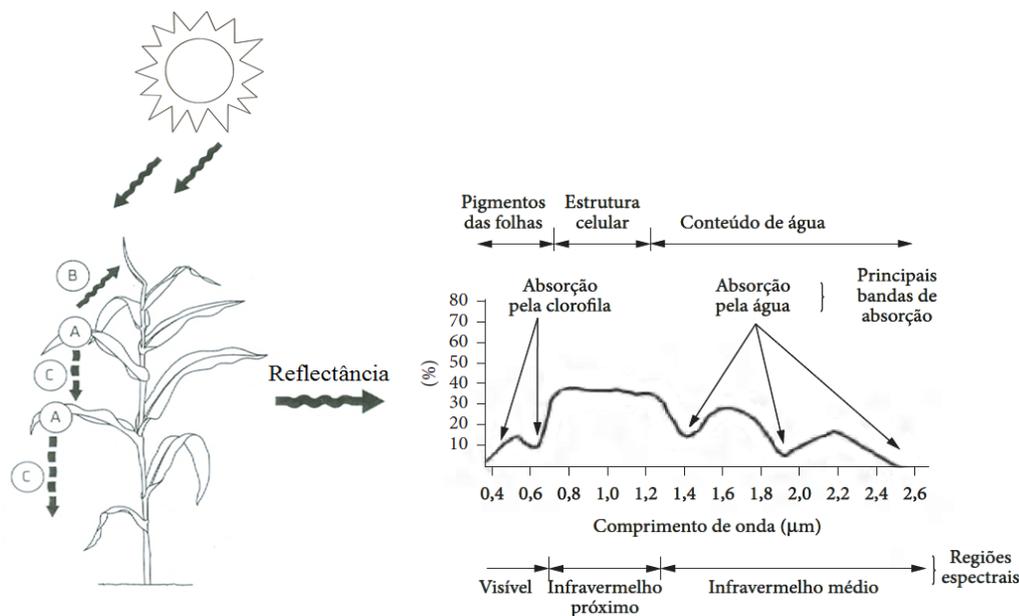


Figura 3 - Interação da REM proveniente do sol com a vegetação e seu respectivo comportamento espectral, onde (A) energia absorvida, (B) refletida e (C) transmitida.
 Fonte: Adaptado de Moreira (2011).

3.2.3. Níveis de aquisição de dados

Segundo Moreira (2011) a aquisição de dados pode ser em nível terrestre, suborbital e orbital. Em nível terrestre, utiliza-se de torres e sistemas radiométricos a campo, onde o comportamento espectral dos alvos é obtido a curta distância, refletindo em resultado com maior fidelidade ao que se investiga, porém, é restrita a pequenas áreas devido à demora na aquisição dos dados e baixa cobertura da mesma. O nível suborbital, utiliza-se de aeronaves tripuladas ou não, levando consigo câmeras fotográficas, sensores multiespectral, hiperespectral, termal e radares, para a coleta de dados dos alvos desejados. Em nível orbital, os dados são obtidos através de sensores a bordo de satélites (NOVO, 2010), cobrindo grandes áreas e repetida vezes, porém com perda da resolução espacial e temporal, tornando muitas vezes difícil a interpretação dos dados.

3.2.4. Radiância e reflectância

Frequentemente no sensoriamento remoto é utilizado diferentes grandezas que são resultados da interação REM com os alvos da superfície terrestre sendo medida pelos sensores de diferentes maneiras, seguindo uma série de termos e leis físicas. A forma com que os sensores registram a REM pode ser mensurada de diferentes maneiras. Sendo, frequentemente

utilizadas grandezas conhecidas como radiância e reflectância, independente do comprimento de onda. Um mesmo sensor é capaz de registrar e disponibilizar ambas ou mais grandezas.

A radiância é uma medida feita pelos sensores que provém de uma densidade de fluxo radiante que deixa um elemento de área da superfície do terreno sendo propagado por uma direção definida. Porém, a densidade de radiação que chega a superfície terrestre é muito variável devido a diferentes absorções e interações que ocorrem nos gases constituintes da atmosfera, além de ser variável durante o dia, mês e horário. Estas diferentes densidades de radiação dificultam o estudo e interpretação dos dados de um determinado alvo, mesmo que os alvos não tenham sofrido alterações.

Estes problemas podem ser resolvidos utilizando no momento em que o sensor mede a radiância, um objeto considerado como padrão lambertiano de máxima irradiância, como exemplo o sulfato de bário, teflon, Spectralon[®], entre outros. A razão entre a radiância e a irradiância estabelece um conceito muito utilizado no sensoriamento remoto conhecido como reflectância, sendo um valor adimensional, expresso em porcentagem. Deste modo, como um padrão é utilizado, alterações devido ao horário, dia e mês é minimizado tornando os dados mais consistentes e fidedignos ao alvo de estudo.

3.2.5. Tipos de sensores

Quando se realiza o estudo dos alvos de interesse aplicando as técnicas do sensoriamento remoto, existe uma série de equipamentos capazes de capturar o fluxo de REM e processar esta informação em dados passíveis de interpretação, tais equipamentos são classificados dependendo do número de bandas espectrais, divididos em sensores multiespectrais e hiperespectrais, a resolução espectral, e quanto ao princípio de funcionamento, sendo classificados em sensores imageadores ou não imageadores (STEINER et al., 2008).

3.2.6. Sensor imageador multiespectral

Os sensores multiespectrais foram os primeiros sistemas de sensores inventados. Tipicamente avaliam a informação espectral de objetos em várias bandas de ondas relativamente amplas. Um dos primeiros sensores multiespectrais que impulsionou o estudo do sensoriamento remoto foi o lançamento do satélite ERTS-1 no ano de 1972 pelo Estados Unidos, sendo posteriormente denominado Landsat-1. Este sensor possibilitava a obtenção de

informações nas bandas que compreendiam a região do visível, infravermelho próximo e termal, disponibilizando quatro imagens espectrais. Apresentava resolução espacial de 79 m cobrindo uma área de 185 km com revisita a cada 16 dias.

Posteriormente, outros sistemas foram lançados, sendo denominados de Landsat-2, Landsat-3, Landsat-4, Landsat-5, Landsat-7, CBERS, SPOT, IKONOS, entre outros. Estes sensores possibilitaram o conhecimento e estudo de características das vegetações e outros alvos da superfície terrestre de maneira diferenciada com vasta riqueza de informações.

Atualmente, com o rápido desenvolvimento da tecnologia e miniaturização dos sistemas de sensores, diversos equipamentos estão disponíveis no mercado. Entre estes, a utilização de câmeras digitais tem-se tornando cada vez mais presente no estudo de problemas na agricultura, devido aos custos reduzidos, compacto e possibilidade de transporte em VANT's, além de poder proporcionar excelentes resultados, desde que a utilização destes equipamentos seja seguida de calibrações em laboratório.

São equipamentos constituídos por uma matriz de fotossensores podendo ser compostos por dois tipos de sensores, o CCD (*Couple Charge Device*) e o CMOS (*Complmentary Metal Oxide Semiconductor*), capazes de captar a REM entre 350 e 1.100 nm (LEBOURGEOIS et al., 2008). Os fotossensores CCD são como células de memória e convertem a entrada da REM em elétrons. Quando ocorre a acúmulo de carga, os conteúdos dos fotossensores são então convertidos de um sinal analógico para um sinal binário digital (1, 0) por um “*Frame grabber*” (conversor analógico para digital), e transmitidos para o microprocessador onde transformam o sinal em imagem com base nas leituras binárias de 1 e 0, formando os pixels da imagem. Já os fotossensores CMOS são projetados para produzir uma saída digital e não necessita de conversão, são mais eficientes energeticamente e mais baratos para ser produzidos, assim como a aquisição das imagens serem mais rápidas.

Com a utilização de filtros ópticos intercambiáveis de diferentes comprimentos de onda, é possível o uso de distintas bandas espectrais que melhor representa o alvo em estudo. Porém, este sistema é restrito a poucas bandas espectrais, devido à necessidade de várias câmeras com cada filtro específico, além de ter que trabalhar em uma ampla faixa do espectro eletromagnético, podendo obter dados muitas vezes não fidedignos ao objeto em estudo. Outra limitação de uso é que o produto disponibilizado por estes sensores é através do *Digital Number*, necessitando conversões para radiância e/ou reflectância. Segundo Honkavaara et al., (2009), os valores de *Digital Number* podem sofrer alterações de acordo com as condições de iluminação e atmosféricas no momento do registro das imagens, sendo necessário o

conhecimento radiométrico para a obtenção de informações espectrais fidedignas sobre os alvos em estudo (KELCEY e LUCIEER, 2012; DEL POZO et al., 2014).

3.2.7. Sensor imageador e não imageador hiperespectral

A utilização de sensores hiperespectrais imageadores ou não-imageadores são as tecnologias mais recentes e promissoras para aplicação no estudo de plantas. Trata-se de uma tecnologia que tem recebido amplo interesse na pesquisa agrícola, através da detecção de mudanças nas características biofísicas e metabólicas nos tecidos das plantas (WEST et al., 2010), além de potencial de aplicação e o tipo de dados que pode gerar (CAMPBELL, 2007).

Tais sensores operam em centenas de bandas espectrais contíguas e estreitas, com altíssima resolução espectral e espacial, oferecendo grande potencial para melhorar a avaliação, identificação e classificação de problemas na agricultura, através da identificação da “assinatura” espectral ou “resposta espectral” que cada objeto apresenta. Uma vez identificado, tais objetos podem ser classificados e diferenciados através desta assinatura.

As faixas de comprimento de onda que os sensores hiperespectrais podem captar informações variam desde 350 nm até mais de 3.000 nm.

Frequentemente, é comum a utilização do sensor CCD que é sensível no espectro visível e no infravermelho próximo (350 – 1000 nm), enquanto outros sensores, como exemplo, InGaAs (*Indium Gallium Arsenide*) e MCT (*Mercury Cadmium Telluride*) operam melhor na região 1.000 a 2.500 nm. No estudo da vegetação, usualmente é fixado os intervalos de comprimento de onda de 350 a 1.000 nm, os quais representam melhor a variabilidade espectral da vegetação.

Enquanto o sistema hiperespectral não imageador trabalha disponibilizando apenas dados numéricos de radiância e/ou reflectância, os sistemas hiperespectrais imageadores, além de disponibilizar os dados numéricos, também fornece a imagem da área estudada, sendo formada por milhares de pixels. Cada pixel desta imagem é constituído pelo empilhamento de vários comprimentos de onda, formando um eixo representado pela letra grega “ λ ” (lambda), podendo estes dados serem em radiância e/ou reflectância do(s) alvo(s).

Com isso, expressões como *hypercube*, *spectral cube*, *data cube* são frequentemente utilizados para expressar a forma da imagem, sendo ilustrada em formato 3D (Figura 4), onde no eixo “x” e “y” representa a dimensão espacial (resolução da imagem) e em “profundidade - z” os comprimentos de onda (λ).

Deste modo, a combinação de imagem e espectroscopia, em uma imagem hiperespectral, proporciona melhor compreensão do objeto em estudo, pois é possível a visualização das características físicas e geométricas do objeto, assim como a resposta espectral. Quando comparado com os sistemas multiespectrais, os mesmos podem não fornecerem informações da real condição da vegetação ou do(s) alvo(s) estudado(s), uma vez que são limitados pelo número de bandas espectral e, também, pela largura destas, impossibilitando obter a “assinatura espectral” ou a identificação de comprimentos de ondas mais sensíveis a condição estudada.

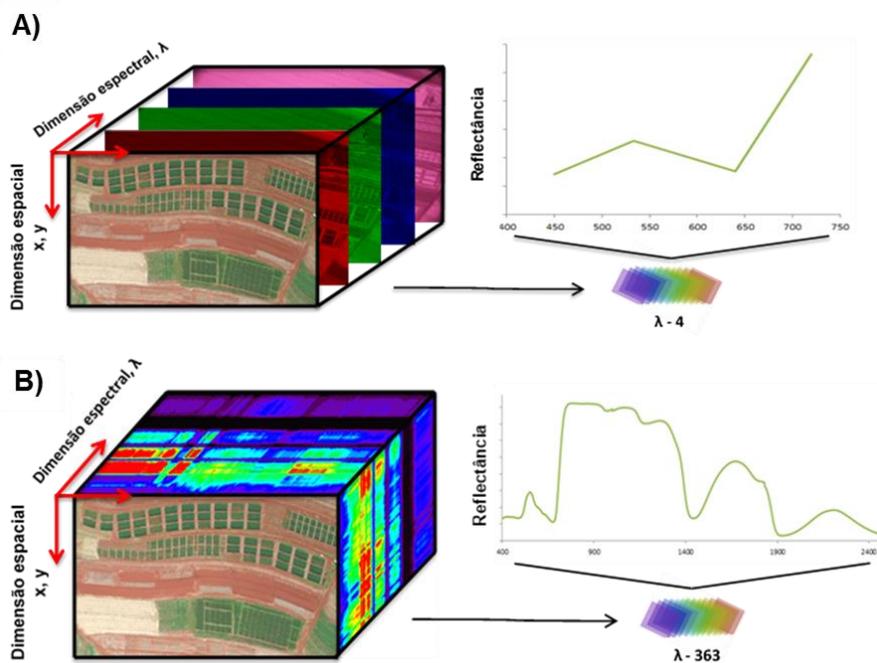


Figura 4 - Diferenças entre o sistema multiespectral obtido por câmeras digitais (A) e o sistema imageador hiperespectral (B).

3.3. Utilização de VANT's para o monitoramento remoto de culturas agrícolas

O monitoramento e estudo de alvos da superfície terrestre por meio de imagens de satélites é frequentemente restrito e inviável na agricultura (WU et al., 2007), devido ao alto custo na aquisição das imagens, baixa resolução temporal e espectral (por exemplo, Landsat, ASTER, SPOT5), além da possível presença de nuvens no momento da aquisição dos dados. Quando é necessário a avaliação de pequenas áreas, como exemplo, experimentos a campo, torna-se impossível de adquirir informações confiáveis das parcelas experimentais, onde só são úteis em áreas de grande dimensão. Mesmo com o lançamento de novos satélites com alta

resolução (por exemplo, WorldView-2, GeoEye-1) não é possível avaliar situações emergentes como estresse nutricionais, doenças, déficit hídrico, entre outros problemas.

Recentemente, com a rápido desenvolvimento e popularização dos veículos aéreos não tripuláveis (VANT's), e o avanço na tecnologia e miniaturização dos sensores, tornou-se mais prático o monitoramento e estudo de alvos da superfície terrestre em relação aos satélites. Além disso, os VANT's estão cada vez mais acessíveis para pesquisadores e agricultores (SWAIN et al., 2010).

Por capturar imagens próximos aos alvos em estudo, obtém-se resolução espacial na ordem de centímetros e alta resolução temporal, pois é possível o sobrevoo da mesma área diariamente, tornando possível de identificar alterações importantes no desenvolvimento das plantas. Portanto, as imagens adquiridas por VANT's podem ser uma alternativa prática para imagens de satélite.

Alguns exemplos de utilização de VANT's têm-se aplicado no monitoramento florestal (GETZIN et al., 2014, AICARDI et al., 2016, MERINO et al., 2012, ZHANG et al., 2016), geologia (BEMIS et al., 2014, VASUKI et al., 2014), geomorfologia (OLEIRE-OLTMANN et al., 2012), avaliação do comportamento espectral da cultura do milho e trigo submetido à diferentes doses de nitrogênio (ZAMAN-ALLAH et al., 2015, QUEMADA et al., 2014, HONKAVAARA et al., 2013; LELONG et al., 2008), análise fenotípica em milho utilizando imagem multiespectral (ZAMAN-ALLAH et al., 2015), modelagem espectral, espacial e modelos de superfície na cultura do milho (GEIPEL et al., 2014), quantificação de nitrogênio em arroz (TIAN et al., 2011), estresse hídrico (ZARCO TEJADA et al., 2012), entre outros.

Entre as plataformas disponíveis, existem os pequenos aviões não tripuláveis (HUNT 2005; HUANG et al., 2008; LALIBERTE et al., 2010), helicópteros (SUGIURA et al., 2002; SWAIN et al., 2007; BERNI et al., 2009a, b), planadores motorizados (LELONG et al., 2008), paraquedas motorizados (paraglider) (LELONG et al., 2008; ABER et al., 2010) e multirotores (KENDOUL et al., 2007; NEBIKER et al., 2008; PRIMICERIO et al., 2012).

Em adicional a ampla variedade de plataforma disponíveis para levantamento, existem numerosos tipos de sensores que podem ser acoplados para coleta de dados. Alguns exemplos de sensores têm-se câmeras digitais fotográficas (INOUE et al., 2000; LEWIS, 2007; LELONG et al., 2008; NEBIKER et al., 2008), sensores hiperespectrais (MITCHELL et al., 2012; ZARCO-TEJADA et al., 2012), scanner 3D (YI LIN et al., 2011; WALLACE et al., 2012; USSYSHKIN et al., 2011), câmeras termais, entre outros.

Porém, vale ressaltar, que embora tais equipamentos estão cada vez mais acessíveis, observa-se a utilização de câmeras digitais acopladas em VANT's de forma inadequada, pois o comportamento espectral sofre alterações devido a interferências atmosféricas, iluminação e ruídos do próprio equipamento, necessitando realizar a calibração destes sensores buscando obter informações realmente confiáveis dos alvos estudados.

3.4. Processamento de imagens

As imagens adquiridas por VANT's possuem maior homogeneidade radiométrica do que imagens obtidas por satélites, devido, principalmente a menor altura de aquisição (LELONG et al., 2008). Porém, há necessidade em realizar correções como a atribuição de coordenadas geográficas aos pixels, transformando os dados contidos nas imagens em informações geolocalizadas (FLORENZANO, 2011). Estas correções são necessárias, pois geralmente, devido ao peso baixo destas plataformas e baixa altura de voo, estão sujeitas a oscilações por conta dos ventos, tornando menos estável no momento da aquisição das imagens, resultando em diferentes resoluções espaciais e/ou diferentes ângulos de visão de uma imagem para outro ao longo do mesmo voo (LELONG et al., 2008), como também, distorção geométrica (LELONG et al., 2008; XIANG e TIAN, 2011).

Outra característica importante é o número elevado de imagens adquiridas dos alvos em estudo, buscando registrar imagens sem “borrões”, resultando em aumento do volume de dados (ABER et al., 2010). Um ponto muito importante e ignorado por muitos pesquisadores e empresas que utilizam imagens obtidas por VANT's no estudo da vegetação, é a correção e conversão do ‘*Digital number*’ das imagens para valores de reflectância, padronizando as informações através de modelos matemáticos-estatísticos para conversão, utilizando da reflectância de alvos conhecidos em laboratório e a campo, tornando-se assim, passível de obter dados fidedignos aos alvos em estudo.

Crusiol et al., (2017), propôs diferentes modelos matemáticos para conversão do ‘*Digital number*’ para valores de reflectância de imagens obtidas por câmeras digitais semi-profissionais acopladas a VANT's, utilizando de placas de diferentes cores dispostas no campo no momento da aquisição das imagens, correlacionando com valores de reflectância obtidos em laboratório com espectrorradiômetro. Os resultados obtidos demonstraram ser possível e estatisticamente confiável a conversão das imagens antes do cálculo de índices de

vegetação. Hunt, 2005; Berni et al., (2009), também ressaltam a importância da conversão antes do cálculo dos índices de vegetação.

3.5. Índices de vegetação

Índices de vegetação (IV's) têm sido utilizados amplamente no estudo e monitoramento de culturas agrícolas. Resultam de combinações lineares de dados espectrais (reflectância) de diferentes bandas do espectro eletromagnético que tem por finalidade realçar características da vegetação em relação ao solo e a outros objetos da superfície terrestre. As faixas do espectro eletromagnético situadas no vermelho e infravermelho próximo são as mais utilizadas, pois contém mais de 90% da variação da resposta espectral da vegetação, realçando características importantes, sendo passível de correlacionar com parâmetros biofísicos das plantas (ROSA, 2007).

Existe mais de 80 IV's relatados na literatura, como exemplo o GNDVI (Índice de Vegetação da Diferença de Verde Normalizado) proposto por Gitelson et al., (1996), RNIR (Razão entre o Vermelho e o Infravermelho Próximo) proposto por Richardson e Wiegand (1977), o GNIR (Razão entre o Verde e o Infravermelho Próximo) proposto por Bausch e Duke (1996), SAVI (Índice de Vegetação Ajustador do Solo) proposto por Huete (1988), entre outros. São empregados nos estudos que buscam caracterizar parâmetros biofísicos da vegetação como área foliar, fitomassa, radiação fotossinteticamente ativa absorvida, produtividade, entre outros parâmetros. Entre todos os índices, um dos mais importantes e amplamente utilizado é o índice de vegetação de diferença normalizada (NDVI) obtido pela razão dos comprimentos de onda da banda vermelha e infravermelho próximo.

A utilização de IV's na caracterização de deficiência nutricional em plantas, têm se tornado cada vez mais importante para o rápido manejo da adubação de correção evitando maiores perdas na produtividade. Segundo Ponzoni (2001); Silva Júnior (2007), as deficiências nutricionais são passíveis de serem detectáveis pela reflectância e pelo índice NDVI, pois ocorrem alterações fisiológicas e estruturais na planta que promovem alteração no comportamento no espectro de reflectância.

Segundo Wang et al., (2012), o K promove alterações no comportamento espectral em folhas de milho. Cheng et al., (2003), trabalhando com milho de verão, encontraram correlação significativa entre os espectros de reflectância e teor de clorofila, sendo possível distinguir bandas do espectro sensíveis ao estresse nutricional em diferentes estádios de

crescimento, podendo esta correlação ser utilizada para estimar a condição de estresse nutricional.

Osbourne et al., (2007) trabalhando com doses de nitrogênio e fósforo em milho, encontraram o maior valor de R^2 para o índice GNDVI, obtido de dados de imagem multiespectral, demonstrando a eficiência na utilização do índice para estimar a produção de grãos e deficiência destes nutrientes. Os mesmos autores, relataram que a reflectância no infravermelho próximo e na região azul do espectro eletromagnético, foram os que melhores destacaram para identificação da deficiência inicial de fósforo em milho quando as plantas estavam no estágio de desenvolvimento V6 e V8, por outro lado, a concentração de nitrogênio na planta foi melhor predita utilizando a reflectância das bandas do vermelho e verde do espectro.

3.6. Estatística multivariada – modelos de regressões pelo método dos mínimos quadrados parciais (PLSR)

Quando se trabalha com sensores hiperespectrais o volume de dados obtidos sobre os alvos de interesse contém centenas e até mesmo milhares de informações, sendo considerado como variáveis respostas para o sensoriamento remoto.

Estes grandes volumes de dados frequentemente são trabalhados no campo univariado da estatística perdendo, por muitas vezes, informações extremamente importantes, pois é realizada a seleção de regiões do espectro eletromagnético que compreende as regiões de maior interesse ao alvo estudado, como exemplo a região do vermelho, verde, azul e infravermelho próximo. Tal procedimento é realizado objetivando a redução na dimensionalidade dos dados adquiridos, tornando mais facilmente manipuláveis e interpretáveis. Porém, geralmente devido a realização da média aritmética dos diferentes comprimentos de onda constituintes de tais regiões do espectro eletromagnético, os dados hiperespectrais são simplificados em poucas bandas espectrais, nem sempre representativa das condições das plantas ou mascarando informações extremamente importantes.

Há, portanto, a necessidade em trabalhar com todas as variáveis respostas (comprimentos de onda), obtendo informações extremamente importantes sobre todo o espectro eletromagnético e também as possível inter-relações entre as mesmas, identificando diferenças sutis muitas vezes não observada por técnicas estatísticas menos robustas.

Entre todos os procedimentos multivariados existentes, o método de regressão por quadrados mínimos parciais (*Partial Least Square Regression* – PLSR) é uns dos mais

importantes e frequentemente utilizado para predição de um conjunto de variável(is) dependente(s) (matriz y) de um grande conjunto de variáveis independentes (matriz x) (NEVES, 2012), ou seja, a predição de atributos físicos e/ou químicos dos alvos a partir dos valores de reflectância dos mesmos.

Esta regressão é baseada no uso de fatores PLSR onde cada fator é definido como uma combinação linear das variáveis originais da matriz x que melhor modelam a(s) variável(is) dependente(s) da matriz y (ALMEIDA, 2009).

Este método envolve também o procedimento de análise por componentes principais (CP's), onde a primeira componente principal (CP₁) correspondente ao maior autovalor é, por definição, a direção no espaço de X que descreve a máxima quantidade de variância explicada das amostras. Quando a variância de um conjunto de dados não puder ser mais explicada pela primeira componente principal, um segundo componente principal perpendicular ou ortogonal ao primeiro será utilizado. Este processo prossegue até que toda a variância seja explicada pelos componentes utilizados (ALMEIDA, 2009), conforme visualizado na Figura 5.

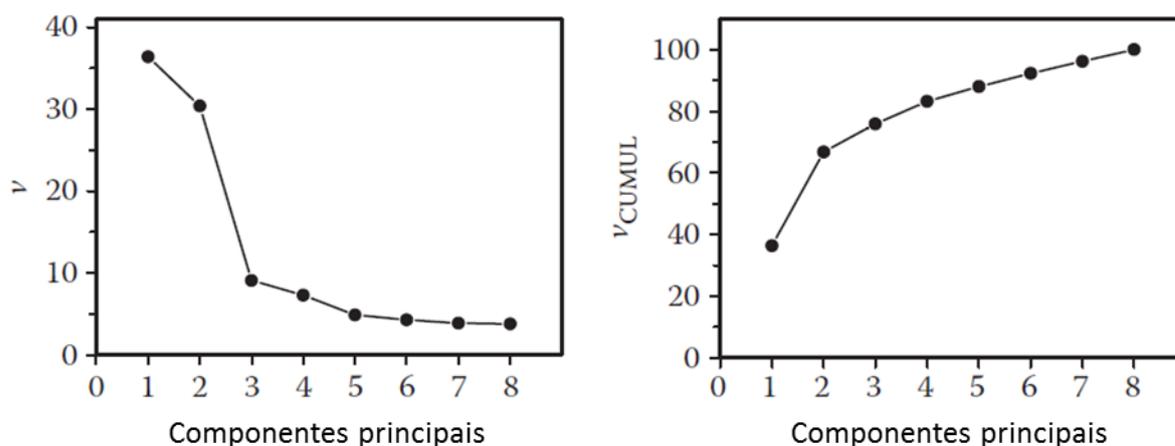


Figura 5 - Esquerda - Ilustração da variância explicada (eixo y) pelas CP's (eixo x). Direita - variância acumulada (eixo y - V CUMUL) pelo número CP's utilizada (eixo x).

Deste modo, a regressão PLSR busca encontrar um conjunto de vetores base (denominados de componentes principais e/ou variáveis latentes) para os dados espectrais e um conjunto separado de vetores base para as variáveis desejadas (produtividade, concentração dos nutrientes) e, em seguida, relacioná-los (ALMEIDA, 2009).

O ponto fundamental do processo, é em estabelecer um número correto de CP's para serem utilizados no modelo de calibração, pois os valores preditos por este modelo dependem diretamente do número de CP's utilizados.

Antes da aplicação do modelo construído, o mesmo deve ser validado com o objetivo de testar e otimizar a sua capacidade preditiva. Sem esta etapa não há sentido em prosseguir. Esta otimização do modelo, envolve a utilização de diversos métodos de validação, sendo o mais comumente utilizado para escolha do número ideal de fatores PLSR, a validação cruzada (*Cross – validation*) (LIEBMANN et al., 2010; SOUZA e POPPI, 2012).

A ideia da validação cruzada é dividir os dados em dois conjuntos, onde no primeiro corresponde aos dados de treinamento (X_{Train}) e o segundo os dados de teste (X_{Test}).

O processo inicia-se retirando uma das amostras, aleatoriamente, entre o conjunto de dados de treinamento. Posteriormente, as amostras restantes (n-1) são utilizadas na calibração buscando a predição da amostra que não foi utilizada na calibração. Este procedimento é realizado até que todas as amostras tenham sido excluídas uma vez.

Após, é comparado os valores previstos com os valores de referência para o cálculo dos erros, chamado de RMSECV (raiz quadrada do erro médio da validação cruzada, ou do inglês, root mean square error cross validation), ficando o modelo que apresentou o menor erro neste processo (FERREIRA et al., 1999; NAES et al., 2002; NEVES, 2012; NASCIMENTO, 2012). O número de fatores a partir do qual não existe variação apreciável no valor de RMSECV é utilizado para determinar o número de CP's a serem utilizados no modelo PLSR.

Definido o número de CP's ideais que irão participar na construção do modelo de predição PLSR, o mesmo pode ser construído e deve ser validado empregando o segundo conjunto de dados de teste (X_{Test}) que não participaram da calibração. Estas amostras devem possuir os valores a ser preditos (produtividade, concentração dos nutrientes) para avaliar a real capacidade de previsão do modelo. De maneira análoga, calcula-se o valor do erro, denominado neste caso de RMSEP (Raiz Quadrada do Erro Médio da Predição, ou do inglês, Root Mean Square Error Prediction).

Neste processo, caso o modelo apresente boa propriedade de previsão, os valores previstos para essas amostras devem ser concordantes com os valores reais e, portanto, em um gráfico contendo estas duas grandezas, os valores das amostras devem estar próximos a uma reta com inclinação de 45°, intercepto próximo a zero (Bias) e inclinação próxima à unidade. Utiliza-se também o coeficiente de determinação R^2 para avaliação da qualidade de ajuste do modelo PLSR (SOUZA et al., 2013).

A utilização de dados espectrais muitas vezes apresenta leituras fora do padrão, sendo consideradas como “outliers”. Quando estas leituras não são removidas ou

identificadas, a qualidade do modelo PLSR pode ser afetada negativamente, prejudicando o ajuste final do modelo. Deve-se, portanto, assegurar de que as amostras formam um conjunto homogêneo (SOUZA et al., 2013).

A detecção dos “outliers” envolve critérios estatísticos para retirada ou não destas amostras anômalas, com a utilização de testes estatísticos como o “leverage”, entre outros.

O "leverage" é uma medida da influência de uma amostra no modelo de regressão. Quando obtido um valor pequeno, a amostra (espectro) em questão pouco influencia na construção do modelo de calibração. Por outro lado, se as medidas experimentais de uma amostra são heterogêneas das outras do conjunto de calibração, ela provavelmente terá alta influência no modelo, podendo ser negativa (FERREIRA et al., 1999). De modo geral, estas amostras heterogêneas são visíveis no gráfico de "scores", sendo avaliado a retirada, ou não, para construção do modelo PLSR.

A utilização de dados de reflectância vis/NIR juntamente com a técnica de regressão multivariada por PLSR tem sido aplicada para predição do teor de óleo em colza e soja (TAJUDDIN et al., 2002; PATIL et al., 2010; WITTKOP et al., 2012), fração de fibras em colza (WITTKOP et al., 2012) amido, proteína, óleo, composição de aminoácidos em milho (RÖMISCH-MARGL et al., 2010; TALLADA et al., 2009; ROSALES et al., 2011), composição de aminoácidos em soja (KOVALENKO et al., 2006), alterações nutricionais em milho (WANG et al., 2007), determinação de espécies florestais (MARTIN et al., 1998), além de trabalhos com espectrorradiometria de solos (CEZAR et al., 2013; NANNI et al., 2004). Porém, pouquíssimos trabalhos buscaram a quantificação de nutrientes foliar em plantas, especialmente o macronutriente K.

Deste modo, a partir desta revisão, não há relatos de trabalhos que objetivaram a avaliação do comportamento espectral de plantas de milho submetidas a diferentes níveis de disponibilidade de K no solo, bem como a quantificação e identificação de condições de deficiência de maneira precoce, através da utilização de sensores multiespectrais e hiperespectrais.

Assim, caso observada relação funcional entre o comportamento espectral e as diferentes condições de fertilidade, tornar-se-ia possível o manejo da adubação potássica por meio de sensores remotos, tornando mais rápido e menos oneroso o processo convencional de avaliação, hoje realizado por meio de análises de solo (NANNI e DEMATTÊ, 2006) e foliar.

4. MATERIAL E MÉTODOS

O resumo do procedimento metodológico e os equipamentos utilizados no experimento estudado estão descritos na Figura 6.

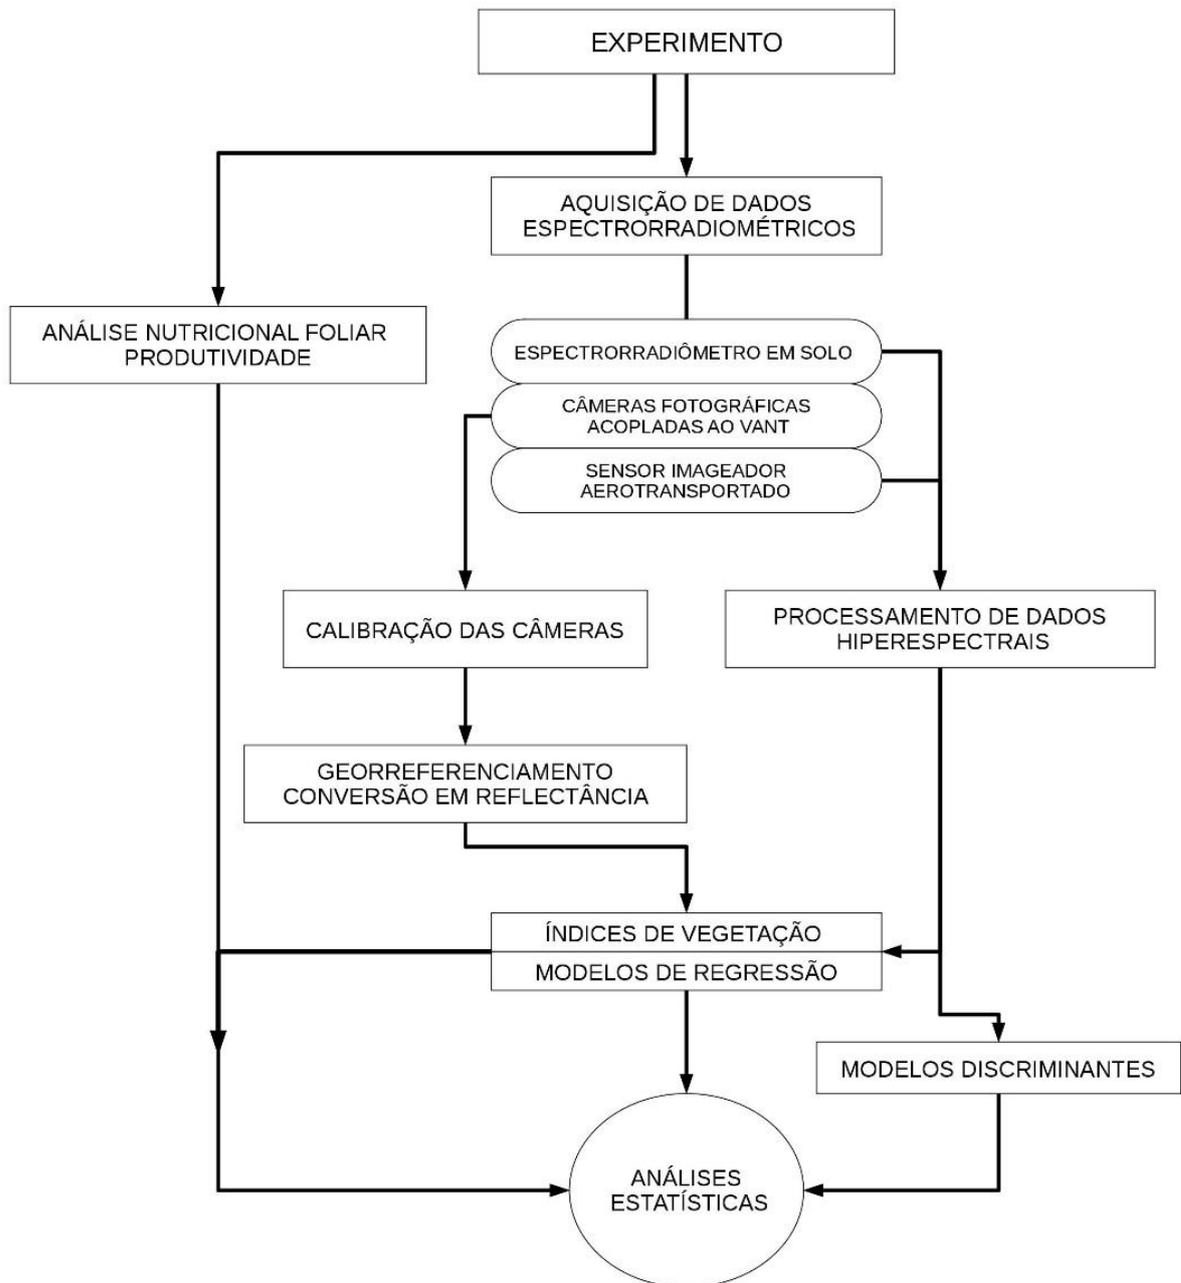


Figura 6 – Fluxograma do processo metodológico utilizado no experimento.

4.1. Caracterização, localização geográfica da área de estudo e implantação do experimento

O distrito de Warta está vinculado ao município de Londrina – PR, localizado entre as coordenadas geográficas de Latitude 23°11'50''S e Longitude 51°12'04''W, apresentando área de aproximadamente 27,73 km² e altitude média de 621 m. O clima da região é descrito, segundo a classificação climática de Köppen, como Cfa, clima subtropical úmido, com temperatura do ar média do mês mais frio inferior a 18°C e temperatura do ar média no mês mais quente acima de 22°C, com verões, quentes e geadas pouco frequentes, com tendência de concentração das chuvas nos meses de verão sendo o volume de chuvas de, aproximadamente, 2.200 mm, porém, sem estação seca definida (IAPAR).

Os solos do município são caracterizados, segundo o Sistema Brasileiro de Classificação de Solos – SBCS (SBCS, 2006) como sendo, em grande parte, compostos por LATOSSOLOS VERMELHO Eutroférico, distroférico e aluminoférico, além de NITOSSOLOS VERMELHO Eutroférico e distroférico, e uma porção de CHERNOSSOLOS (BARROS et al., 2008), decorrente das condições climáticas e geológicas. Os solos da região são caracterizados como sendo férteis e com aptidão para diferentes culturas agrícolas, destacando-se, dentre elas, a cultura do milho, soja e trigo.

A área de estudo compreendeu o experimento em campo de longa duração (início em 1991) em fertilidade do solo com combinações de doses de potássio e fósforo, localizado na EMBRAPA Soja, Rodovia Carlos João Strass - Distrito de Warta, Estado do Paraná, Brasil.

O experimento está implantado no delineamento em blocos completos ao acaso (DBC) com 4 blocos e 12 tratamentos, sendo a adubação (tratamentos) manejada de modo que possibilitam-se ampla variação na disponibilidade de fósforo e potássio no solo, sendo possível detectar sintomas visuais de deficiência nas plantas de forma combinada e isolada destes nutrientes.

Nas parcelas experimentais estão distribuídas diferentes doses de fósforo e potássio (tratamentos), conforme visualizado na Tabela 2.

Tabela 2. Doses de fósforo e potássio aplicados para os tratamentos estabelecidos.

Tratamentos	Verão		Inverno	
	P ₂ O ₅	K ₂ O	P ₂ O ₅	K ₂ O
T-2	0	0	50	50
T-3	0	0	50	0
T-6	60	0	50	50
T-12	60	80	50	50

¹ TSP – Superfosfato triplo (44% de P₂O₅), ² KCl – Cloreto de potássio (60% de KCl).

As parcelas experimentais possuem dimensões de 8 x 20 metros com área total de 160 m² contendo 16 linhas de plantio, sendo considerado como área útil 3 x 15 metros (45 m²) correspondendo as 6 linhas centrais.

O solo da área experimental foi classificado, segundo o Sistema Brasileiro de Classificação de Solos (SBCS, 2006) como sendo LATOSSOLO VERMELHO eutroférico de textura muito argilosa. As características químicas do solo são apresentadas no Apêndice A.

A área experimental vem sendo cultivada sob o sistema de plantio direto, com sucessão soja/milho safrinha ou com soja/trigo. Foi utilizado o híbrido de milho DOW-2B655PW considerado como sendo precoce de porte médio e exigente em fertilidade do solo. A semeadura foi realizada no dia 15 de março de 2017, utilizando de 3,5 sementes por metro linear e espaçamento de 0,50 metros entre linha de plantio. A emergência ocorreu no dia 24 de março de 2017. O controle de plantas daninhas foi realizado com aplicação do herbicida Soberan na dosagem de 240 mL ha⁻¹ + Roundup na dosagem de 3.000 mL ha⁻¹ 18 dias após a emergência das plantas (DAE). O controle de pragas foi realizado em 18 DAE utilizando o inseticida Engeo pleno (300 mL ha⁻¹) + Premio (100 mL ha⁻¹) e em 30 DAE aplicando Engeo pleno (300 mL ha⁻¹). A adubação nitrogenada foi realizada a lanço aplicando 70 kg N, utilizando como fonte de N a uréia (45%).

A colheita foi realizada no dia 04/09/2017, compreendendo as 6 linhas centrais, evitando-se efeitos de bordadura.

Os tratamentos estudados abrangeram aos relacionados com a adubação potássica, buscando a caracterização espectral dos mesmos quando submetidos a diferentes condições de

disponibilidade deste elemento, sendo avaliados o T-2, T-3, T-6 e T-12, onde o T-3 é caracterizado como de extrema deficiência, apresentando sintomas visíveis, T-2 e T-6 denominado de “fome oculta” (deficiência “leve”, sem sintomas aparente), T-12 considerado como o padrão em adubação.

4.2. Obtenção das imagens aéreas por VANT

Para obtenção das imagens aéreas foram realizados voos com um VANT octocóptero modelo Tarot Iron Man 1000 composto de fibra de carbono 3k, equipado com motores brushless de 340 KV modelo T-Motor MN5212 e potência de 600 W, utilizando hélices de fibra de carbono 3k de 17 x 5.5 polegadas (Figura 7). O VANT foi desenvolvido para transportar sensores multiespectrais e hiperespectrais e possui capacidade de “*payload*” 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. O VANT foi equipado com sistema de estabilização de câmera para evitar vibrações durante a realização do voo.

No VANT foi acoplado um sistema de transmissão de vídeo trabalhando na frequência de 5.8 Ghz com 2.000 mW, onde transmite a imagem de uma das câmeras acopladas 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. O VANT é operado através de um rádio controle FUTABA de 2.4 Ghz com 14 canais, sendo um dos canais configurado para realizar o disparo das câmeras sob o alvo estudado. A altitude de voo foi estipulada para cobrir todo o experimento mediante uma única foto, sendo obtido quando o voo atingia 400 metros em relação ao solo. Para evitar o efeito “*Drift*” (distorção) das imagens foram realizadas várias capturas das cenas, sendo posteriormente escolhida a critério visual a imagem que apresentasse nenhuma ou menor distorção.



Figura 7 - VANT octocóptero utilizado durante o período das avaliações.

Foi acoplado ao vant duas câmeras digitais modelo Fujifilm S200-EXR (12.1 megapixels) sendo uma operando nas bandas do vermelho (Red – R), verde (Green – G) e azul (Blue – B) com um filtro UV/IR *Cut*, que proporciona o bloqueio da passagem da radiação ultravioleta e infravermelho, permitindo a passagem dos comprimentos de onda da região do visível e, a outra, operando na banda do infravermelho próximo (NIR), utilizando um filtro de 760 nm, que proporciona a passagem da radiação do infravermelho nos comprimentos de onda superiores a 760 nm.

Ambas as câmeras são constituídas por uma matriz de fotossensores CCD de 8 bits (*Couple Charge Device*) com capacidade de operação na faixa entre 380 a 1.000 nm do espectro eletromagnético, sendo este intervalo de comprimento de onda superior a câmeras fotográficas convencionais.

O foco das câmeras foi travado para evitar possíveis variações no sensor, também foi realizado o balanço de branco buscando a padronização da condição de iluminação no campo. As câmeras foram configuradas no modo EXR, onde controla automaticamente a abertura do diafragma e o tempo de abertura do obturador, de acordo com a incidência luminosa, sendo necessário para a sensibilização do sensor, também foram ajustadas para registrar as imagens em formato RAW tamanho *Large 4:3* com 4000x3000 pixels, com ISO de 800.

Antes da aquisição das fotografias em campo, as câmeras foram calibradas em laboratório em condição controlada para avaliar a resposta radiométrica e a distribuição da luminosidade no sensor. Para a avaliação, foi utilizada a esfera integradora óptica modelo UMKK-280, fabricada pela Gigahertz Optik Inc., que proporciona a emissão e distribuição homogênea da luminosidade, sendo possível a aquisição de imagens em ambiente controlado e estimar o ruído interno das câmeras obtendo o valor considerado como *offset*.

Posteriormente, as câmeras foram montadas em um suporte tripé distanciada aproximadamente 25 cm dos alvos de calibração em relação à lente da mesma. Para

sensibilização do sensor, foi utilizado uma fonte luminosa artificial com lâmpada halógena de 600W disposta geometricamente a 30° em relação aos alvos.

De maneira análoga tal procedimento foi realizado com o espectrorradiômetro ASD Fieldspec 3 Jr., onde foi utilizado uma lente de 8° distanciado a 8 cm dos alvos. A utilização do espectrorradiômetro ASD Fieldspec 3 Jr. foi necessário para obter os valores de reflectância dos alvos de calibração para, posteriormente, utilizá-los como parâmetros para conversão do número digital – ND das câmeras para reflectância.

Os alvos utilizados para obter os valores referência de calibração, foram vinis cortados no formato quadrado com 5x5 cm, de diferentes cores, sendo elas: vermelho, verde, azul, cinza, preto e branco (LEBOURGEOIS et al., 2008; KELCEY e LUCIEER, 2012; CRUSIOL et al., 2016).

Após a obtenção das imagens, as mesmas foram convertidas do formato .RAW para .TIFF e extraídos os valores do número digital – ND dos alvos de calibração no software ENVI, e realizado a correlação entre os valores da média dos números digitais – ND e os valores de reflectância dos alvos obtidos pelo espectrorradiômetro.

4.3. Processamento das imagens obtidas por VANT

As imagens obtidas em campo pelo VANT primeiramente foram selecionadas manualmente buscando as que apresentassem menor distorção, devido a oscilações ocasionadas por ventos no momento dos voos. Posteriormente, foram convertidas do formato .RAW para .TIFF, através do software FinePixViewer da própria fabricante das câmeras. As imagens obtidas pela câmera infravermelha passaram por um processo extra de conversão de colorida para preto e branco, necessário para a equalização das bandas, sendo após convertida em .TIFF.

Feita a seleção e conversão, foram realizadas o georreferenciamento das imagens do visível e infravermelho. Tal procedimento é necessário devido à aquisição das imagens serem através de duas máquinas dispostas lado-a-lado, portanto existem diferenças no pixel de um mesmo alvo devido à disposição no VANT, sendo necessários processamento e correção mediante o georreferenciamento buscando “unir” os mesmos pixels.

O processamento foi realizado no software de sistema de informação geográfica QGIS 2.18 disponibilizado gratuitamente e de código aberto. No campo experimental foram coletados pontos de controle através de um GPS Hiper II (Topcon®) nos limites de cada

parcela experimental, além de pontos ao redor da área imageada. No software QGIS 2.18 foi criado um projeto utilizando o sistema de projeção *WGS 84* e, posteriormente realizou-se o georreferenciamento de uma das imagens obtidas pelo VANT no *plug-in* georreferenciador do software, utilizando os pontos de controle. As demais imagens foram georreferenciadas a partir da primeira imagem, buscando a identificação dos pontos de controles conhecidos e comuns. De maneira análoga, prosseguiu-se este processo para as demais imagens e datas de avaliações.

A obtenção dos valores de ND das imagens georreferenciadas foi realizada no software ENVI 5.3[®] - Environment for Visualizing Images – SulSoft através da ferramenta ROI - *Region of interest*, criando um retângulo em cima de cada uma das parcelas experimentais, extraindo os valores de ND nas bandas do vermelho, verde e infravermelho próximo, sendo exportados em formato .txt para realizar a conversão para reflectância.

A conversão foi obtida através da geração de modelos matemáticos de regressão entre os dados de campo e laboratório. Para isso, valores de reflectância de alvos conhecidos (gramado, milho, solo e palhada) foram coletados com o espectrorradiômetro e então os ND dos mesmos alvos foram coletados nas imagens das câmeras digitais, sendo posteriormente correlacionados e gerados modelos de conversão aplicando critérios estatísticos para verificação da qualidade dos modelos obtidos.

4.4. Obtenção de dados espectrorradiométricos das plantas em nível de terrestre

Os dados espectrorradiométricos foram obtidos através do espectrorradiômetro ASD Fieldspec 3 Jr. que opera na faixa espectral de 350 nm a 2.500 nm, apresentando resolução espectral de 3 nm na faixa de 350 nm a 1.400 nm e 30 nm de 1.400 nm a 2.500 nm.

O espectrorradiômetro ASD Fieldspec 3 Jr. (Figura 8) é um sensor hiperespectral não imageador constituído por um fotossensor CCD com sensibilidade de operação na faixa espectral de 350 nm a 1.000 nm, e um sensor *Indium Gallium Arsenide* (InGaAs) com sensibilidade na faixa espectral de 1.000 nm a 2.500 nm.

As leituras de reflectância das folhas foram realizadas através do acessório ASD Plant Probe, que possui uma fonte luminosa artificial constituída por uma lâmpada halógena de 6,5W e um dispositivo de *Clip* com fundo preto que proporciona completo isolamento do alvo de interesse de possíveis interferências de fatores externo, sendo um método não destrutivo de avaliação espectrorradiométrica das folhas. O ASD Plant Probe transmite a

porção da REM que interagiu com as folhas através de um cabo de fibra óptica conectado ao equipamento. Todo o funcionamento do equipamento é gerenciado por um notebook onde também são armazenados os dados radiométricos mensurados.



Figura 8 - ASD Plant Probe com a folha climpada para obter a leitura espectral das plantas de milho no experimento utilizando o espectrorradiômetro ASD Fieldspec 3 Jr.

Antes de iniciar as avaliações, o equipamento permaneceu em funcionamento durante 15 minutos, período este necessário para o pré-aquecimento e estabilização do sistema. Após, o equipamento foi otimizado para eliminação e mensuração de ruídos internos, em seguida realizada a coleta do padrão de reflectância através da leitura da placa de Spectralon (Labsphere[®]) presente no ASD Plant Probe, considerado como padrão lambertiano de reflexão máxima. Após estes procedimentos, iniciaram-se as leituras espectrorradiométricas das folhas das plantas posicionando a face abaxial da mesma sobre o fundo negro presente no acessório do equipamento. As folhas avaliadas compreenderam as situadas no terço superior, selecionando as completamente expandidas. Buscando a representatividade das leituras, foram realizadas mensurações de reflectância em 5 plantas de cada parcela experimental, sendo que cada mensuração é resultado de outras 30 leituras realizadas internamente pelo equipamento. Este processo de repetição de leituras é um artifício que pudesse compensar qualquer possível falha ocorrida durante as leituras do sensor (NANNI, 2000). Todas as leituras foram realizadas em condição de céu limpo, nos horários entre as 10 a 12 horas.

Finalizado as leituras, os dados foram processados no software Viewspec Pro (ASD, 2008) e exportados do formato .asd para .txt para posterior geração de índices de vegetação (IV's) e análise estatística.

4.5. Obtenção dos índices de vegetação pelo espectrorradiômetro, câmeras digitais e sensor imageador hiperespectral aerotransportado AisaFENIX

Resultantes de combinações lineares de dados espectrais (reflectância) de diferentes bandas do espectro eletromagnético, os IV's têm por finalidade realçar características específicas da vegetação em relação a outros objetos ou parâmetros. Nesse sentido, buscando a identificação e caracterização das diferentes condições de disponibilidade de K entre os tratamentos avaliados, vários IV's foram gerados com o propósito em analisar o potencial dos mesmos em evidenciar a influência do K nas plantas, sendo posteriormente avaliados estatisticamente.

Para a obtenção dos IV's utilizou-se a média dos comprimentos de onda nas seguintes bandas do espectro eletromagnético, sendo elas:

Banda Verde (500 - 578nm),

Banda Vermelho (620 - 720nm),

Banda Infravermelho próximo (NIR) (720 - 1000nm).

Esses limites mencionados acima não são fixos, podendo ser estabelecidos conforme cada autor, sendo assim utilizou-se os limites estabelecidos segundo Moreira (2011).

Com relação às câmeras fotográficas, para obter os IV's os números digitais foram extraídos e convertidos para reflectância, sendo posteriormente calculados e realizados os procedimentos estatísticos para avaliar qual(is) o(s) melhor(res) a partir do teste de comparação de médias de Tukey.

Os IV's calculados foram: NDVI (Índice de vegetação por diferença normalizada – ROUSE et al., 1974), GNDVI (Índice de vegetação da diferença de verde normalizado – GITELSON et al., 1996), GNIR (Razão entre verde e infravermelho próximo – BAUSCH e DUKE, 1996), RNIR (Razão entre vermelho e infravermelho próximo – RICHARDSON e WIEGAND, 1977), RVI (Razão entre infravermelho próximo e vermelho – BIRTH e MCVEY, 1968) e GRVI (Razão entre infravermelho próximo e verde – SRIPADA et al., 2006) de acordo com as equações mostradas abaixo.

$$(1) NDVI = \frac{NIR-RED}{NIR+RED}$$

onde,

NDVI = Índice de vegetação por diferença normalizada;

NIR = Média da reflectância dos comprimentos de onda da banda do infravermelho próximo;

RED = Média da reflectância dos comprimentos de onda da banda do vermelho.

$$(2) \text{ GNDVI} = \frac{\text{NIR} - \text{GREEN}}{\text{NIR} + \text{GREEN}}$$

onde,

GNDVI = Índice de vegetação da diferença de verde normalizado;

NIR = Média da reflectância dos comprimentos de onda da banda do infravermelho próximo;

GREEN = Média da reflectância dos comprimentos de onda da banda verde.

$$(3) \text{ RNIR} = \frac{\text{RED}}{\text{NIR}}$$

onde,

RNIR = Razão entre as bandas do vermelho e infravermelho próximo;

RED = Média da reflectância dos comprimentos de onda da banda do vermelho.

NIR = Média da reflectância dos comprimentos de onda da banda do infravermelho próximo;

$$(4) \text{ GNIR} = \frac{\text{GREEN}}{\text{NIR}}$$

onde,

GNIR = Razão entre as bandas do verde e infravermelho próximo;

GREEN = Média da reflectância dos comprimentos de onda da banda verde.

NIR = Média da reflectância dos comprimentos de onda da banda do infravermelho próximo;

$$(5) \text{ RVI} = \frac{\text{NIR}}{\text{RED}}$$

onde,

RVI = Razão entre as bandas do infravermelho próximo e vermelho;

NIR = Média da reflectância dos comprimentos de onda da banda do infravermelho próximo;

RED = Média da reflectância dos comprimentos de onda da banda do vermelho.

$$(6) GRVI = \frac{NIR}{GREEN}$$

onde,

GRVI = Razão entre as bandas do verde e infravermelho próximo;

NIR = Média da reflectância dos comprimentos de onda da banda do infravermelho próximo;

GREEN = Média da reflectância dos comprimentos de onda da banda verde.

4.6. Datas de avaliações ao longo do ciclo de cultura

As avaliações espectrais com o espectrorradiômetro de campo ASD Fieldspec 3 Jr. e o sistema multiespectral acoplado ao VANT foram iniciadas no dia 03/04/2017 no estádio de desenvolvimento V3, aproximadamente 10 DAE. As demais avaliações foram realizadas semanalmente até o completo desenvolvimento da espiga, nos dias 10/04/2017 (V5), 17/04/2017 (V7), 24/04/2017 (V8), 03/05/2017 (V10), 08/05/2017 (V12), e após este período, escalonado a cada 20 dias, aproximadamente, em 26/05/2017 (R1), 16/06/2017 (R3) e 10/07/2017 (R5), sendo estas realizadas no estádio reprodutivo. Todas as avaliações foram realizadas nos horários entre 10 – 12 horas em condição de céu limpo, com intensa radiação solar evitando interferências por nuvens.

4.7. Análise foliar

A coleta para análise química nutricional foi realizada no dia 17/04/2017 (V7), 08/05 (V12) e 16/06 (R3). Para isso, foram coletadas 5 folhas completamente expandida em cada parcela experimental, sendo imediatamente acondicionadas em sacos de papel. Após, as folhas foram secas em estufa de circulação forçada de ar com temperatura de 65°C por um período de 96 h até peso constante. As folhas secas foram processadas em moinho tipo Wiley para obtenção de um pó fino e homogêneo para posterior determinação da concentração de K das amostras. Os dados foram utilizados para modelagem em regressões lineares e multivariada.

4.8. Imageamento com sensor hiperespectral aerotransportado

O imageamento com o sensor hiperespectral foi realizado no dia 17/04/2017 (V7), utilizando do sensor imageador hiperespectral AisaFENIX (SPECIM[®]) aerotransportado. Este sensor é capaz de realizar imagens através de multiplataformas, sendo versátil para acoplar em aeronaves. Também, é possível operar em nível de solo ao tripé e em laboratório no sistema lab-scanner.

O sensor é construído por dois fotosensores, sendo um CMOS (*complementary metal-oxide-semiconductor*) composto por óxido-silício, capaz de operar na faixa o espectro eletromagnético de 380 – 970 nm, registrando informações na porção vis/NIR com resolução espectral de 3,5 nm, e um segundo sensor CMT (*Cadmium-mercury-telluride*) capaz de operar na faixa SWIR de 970 – 2.500 nm, apresentando uma resolução espectral de 12 nm, sendo refrigerado por um sistema *Stirling cooler* com hélio comprimido. O equipamento possibilita operar com 619 bandas espectrais, sendo 344 na região vis/NIR e 275 no SWIR. O campo de visada (*Field of View* - FOV) é de 32,3° e o campo de visada instantânea (*Instantaneous Field of View* – IFOV) é de 0,084°. Tais características permitem a aquisição de imagens com relação 1:1. Ou seja, um sobrevoo de 600 m de altura obtém uma faixa de imageamento de 600 m, com pixel de 0,5 m, podendo, entretanto, ser reamostrado para 0,35 m sem perda da fidelidade dos dados.

O sobrevoo foi realizado com origem do Aeroporto Regional de Maringá - Sílvio Name Júnior, na cidade de Maringá – Paraná, utilizando de um avião bimotor modelo PA-34-200T Seneca II (Piper Aircraft) (Figura 9). No avião foi instalado o sensor AisaFENIX junto com a unidade GPS/IMU modelo OXTS - RT3050 com erro de 10 cm (OXTS, 2016) para coleta de dados referentes às oscilações no avião no eixo *pitch*, *roll* e *yaw* (inclinação, rolamento e rotação no próprio eixo), velocidade e coordenadas geográficas, dados estes utilizados para a correção geométrica das imagens, sendo capturados conforme o deslocamento do avião no momento do registro da cena.

O voo foi realizado nos horários entre 12 – 15 horas, em condição de céu limpo, sem presença de nuvens e com radiação solar intensa. A altitude de voo foi de 600 m para a coleta de imagens com resolução espacial de 0,5 m. Como padrão foi utilizado de três placas de madeira pintadas com sulfato de bário (BaSo₄) dispostas uniformemente em um gramado onde foi realizado um sobrevoo para coletada da radiância das mesmas, na cidade de origem. Os dados obtidos foram utilizados para a conversão da imagem.

A imagem obtida, assim como os dados espectrais, foram corrigidas em laboratório geometricamente, utilizando dados de voo da unidade GPS/IMU, e radiometricamente com correções para presença de aerossóis da atmosfera e vapor d'água. A imagem resultante das correção, foram convertidas em formato .bsq no software ENVI® e importadas no software ATCOR® (ATCOR-4). Neste software, foram criados parâmetros do sensor AisaFENIX utilizado através de dados de voo da unidade GPS/IMU e fatores de correção para presença de aerossóis da atmosfera, onde o produto final, foi a imagem convertida de radiância para reflectância. Posteriormente, as imagens convertidas foram abertas novamente no software ENVI® para a coleta de dados de reflectância das parcelas experimentais e estes exportados para o formato .txt para a realização das análises estatísticas.

Antes da realização da análise estatística dos dados de reflectância, as curvas espectrais foram submetidas a eliminação de ruídos e suavização de inflexões não responsivas, buscando a melhoria na qualidade da análise. Para isso, foi aplicado em todas as curvas o pré-tratamento através do algoritmo Savitzky-Golay, cuja ideia principal é a utilização de uma expressão polinomial, através do método dos mínimos quadrados, para substituir os valores originais pelo valor obtido pelo polinômio utilizado, sendo o produto final a curva suavizada com redução de ruídos indesejáveis.

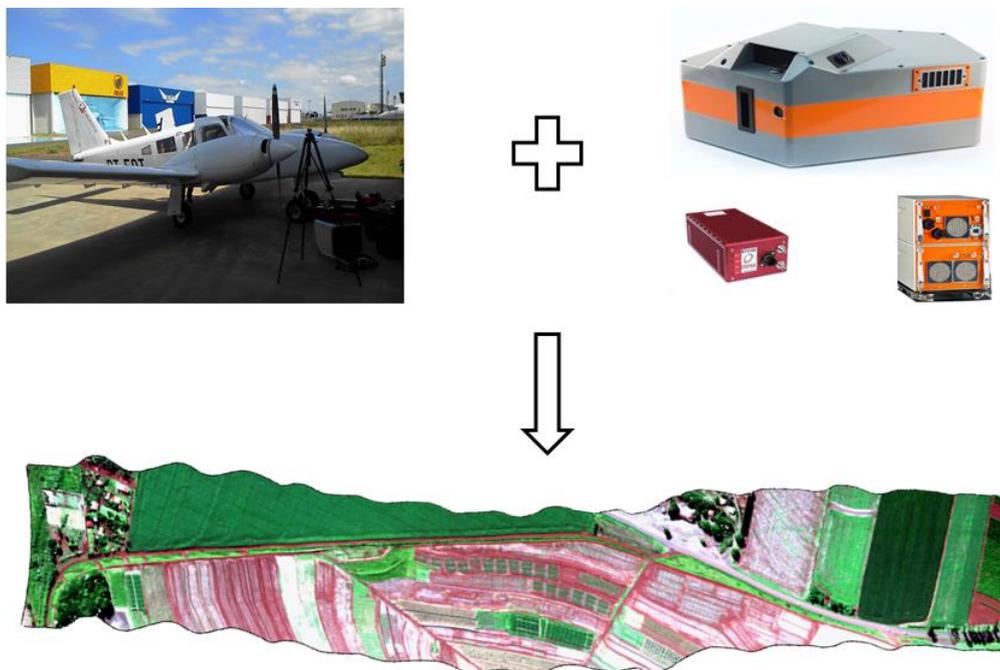


Figura 9 - Representação dos equipamentos para obtenção da imagem hiperespectral a partir do sensor AisaFENIX.

4.9. Análise dos dados

As análises estatísticas dos dados obtidos pelos diferentes sensores durante a condução do experimento foram realizadas em etapas distintas.

No primeiro momento, foram avaliados o comportamento espectral das plantas do milho nas diferentes disponibilidades de fertilidade de K nas parcelas experimentais, gerando-se gráficos médios da resposta espectral, nas folhas, em 03/04 (V3), 10/04 (V5), 17/04 (V7), 24/04 (V8), 03/05 (V10), 08/05 (V12), 26/05 (R1), 16/06 (R3) e 10/07 (R5) obtido pelo espectrorradiômetro em solo (ASD FieldSpec 3 Jr.), sendo no eixo das abscissas plotados os valores dos comprimentos de onda do espectro (nm) e no eixo das ordenadas os fatores de reflectância médios das folhas.

Na segunda etapa, verificou-se o potencial de diferenciação dos tratamentos através dos IV's obtidos pelo espectrorradiômetro em solo (ASD FieldSpec 3 Jr.), pelo sensor hiperespectral aerotransportado AisaFENIX e pelas câmeras digitais acopladas ao VANT, sendo os dois últimos ao nível de pixel, através do teste de comparação múltipla de médias de Tukey ao nível de probabilidade de erro (α) de 5%, sendo submetidos a tal procedimento, somente os IV's que atenderam a pressuposição básica da ANOVA através dos testes de normalidade dos resíduos de Shapiro-Wilk e homogeneidade de variâncias pelo teste de Bartlett ao nível α 5%.

Dos IV's significantes obtidos pelas câmeras digitais acopladas ao VANT, os mesmos foram modelados em regressões lineares para avaliar a capacidade de estimativa da concentração de K nas folhas. As qualidades das regressões foram avaliadas através do coeficiente de determinação (R^2), correlação linear simples de Pearson (r), significância do modelo pelo teste F e significância dos coeficientes da regressão (β_0 , β_1) pelo teste "t", sendo testados ao nível de significância de 5% de probabilidade de erro.

Com relação aos dados obtidos pelo sensor AisaFENIX, estes foram submetidos a técnicas estatísticas multivariadas buscando a diferenciação dos tratamentos T-2, T-6 e T-12 por meio do procedimento de análise por componentes principais (ACP), sendo em seguida, geradas funções lineares discriminantes através do procedimento proc STEPDISC e proc DISCRIM no software SAS (Rotina – APÊNDICE B).

Avaliou-se também, a modelagem das curvas espectrais deste mesmo sensor para a predição da produtividade e da concentração foliar de K foliar por meio da técnica de regressão por quadrados mínimos parciais (*Partial Least Squares Regression* – PLSR), comentado no Tópico 4.9.1.2.

O tratamento T-3 devido a extrema condição de deficiência por K, não foi possível obter o espectro de reflectância. Deste modo, para evitar a contaminação dos dados espectrais pelo solo exposto, optou-se pela não utilização nos procedimentos multivariados.

4.9.1. Análise estatística multivariada dos dados hiperespectrais obtido pelo sensor Aisa FENIX

4.9.1.1. Modelos lineares discriminantes obtidos pelo software SAS

Modelos de regressão lineares têm sido aplicados para estimar diversos elementos nas plantas. Vários pesquisadores demonstraram a capacidade de modelagem através do uso de dados de sensores hiperespectrais para diferenciar nitrogênio, fósforo e potássio foliar (GROSSMAN et al., 1996; LI et al., 2007; TIAN et al., 2011; FERWERDA e SKIDMORE, 2007), avaliar o “status” nutricional em folhas de girassol (PEÑUELAS et al., 1994), entre outros. Deste modo, observa-se que a utilização de dados de reflectância do espectro vis/NIR apresenta potencial para discriminar diferentes nutrientes nas plantas.

Para obtenção das funções discriminantes, inicialmente foi realizado no software SAS o procedimento proc STEPDISC que permite a seleção de variáveis que melhor explicam as diferenças entre os tratamentos estudados, selecionando os melhores comprimentos de onda de todo o espectro de reflectância.

O procedimento proc STEPDISC envolve o critério de seleção de variáveis pelo método conhecido por STEPWISE. Este método 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).

No primeiro passo do algoritmo utilizado, os valores de F parciais considerados para análise de entrada da variável são obtidos através de uma análise de variância para cada uma das n -variáveis candidatas a entrar no modelo separadamente. Dentre as possíveis variáveis significativas, inicia-se a entrada no modelo de discriminação a que apresenta a maior significância, ou seja, a variável que apresenta melhor poder para discriminação dos tratamentos.

Caso ocorra a entrada de alguma variável, o algoritmo inicia a análise sobre uma outra nova variável candidata a entrar no modelo através da comparação dos valores de F parciais para esta nova variável, sendo comparado com um valor de referência escolhida *a priori*, determinante para a entrada ou não da mesma.

O algoritmo também realiza um teste para saída de variáveis, sendo realizada para cada variável separadamente, onde a mesma é tratada como variável resposta e as outras, que já estão no modelo, são tratadas como explicativas (covariáveis); caso o valor F parcial seja menor que o F de referência, o procedimento retira a mesma e reinicia-se a análise para uma outra variável.

Quando nenhuma outra atinge o critério de significância para entrar no modelo, o algoritmo é interrompido indicando que não existe evidências estatísticas significativas entre as n - variáveis para discriminação dos tratamentos. Para a execução deste procedimento, adotou-se o critério de seleção de 10% de probabilidade de erro, tanto para a entrada das variáveis, como para saída das mesmas.

Ao final do proc STEPDISC, é disponibilizado uma tabela com o sumário do procedimento contendo todas as variáveis que mais explicam as diferenças entre os tratamentos estudados, os valores de F , Lambda de Wilk's, p-valor, entre outros critérios para interpretação.

Obtido os comprimentos de onda que mais explicam as diferenças entre os tratamentos estudados, procedeu-se a análise discriminante utilizando o comando proc DISCRIM do software SAS a partir destes comprimentos de onda selecionados no passo anterior.

Este método discriminante de análise permitiu a criação de um modelo preditivo de associação dos tratamentos com base nas características espectrais observadas em cada caso. O procedimento gerou funções discriminantes para cada tratamento estudado em questão, através de combinações lineares das variáveis predictoras (comprimentos de onda) (KARIMI et al., 2005).

Buscando reforçar o modelo obtido, foi realizado uma simulação em que 60% das curvas espectrais dos tratamentos foram utilizados para gerar um modelo discriminante que seria testado pelos 40% restantes. O sistema escolheu aleatoriamente os componentes que fariam parte da análise discriminante (60%) assim como aqueles que seriam utilizados para testar o modelo (40%) (KARIMI et al., 2005). Essa metodologia foi testada por 50 vezes consecutivas, tanto para os dados utilizados no modelo, como para aqueles independentes do

modelo (NANNI et al. 2004; CEZAR et al., 2013). Após, foi gerado o relatório contendo as tabelas de contingência e porcentagem de acerto e erro para cada tratamento estudado.

As curvas espectrais utilizadas para o procedimento foram cortadas no intervalo de 450 a 1.200 nm, regiões estas de melhor representação da variabilidade da vegetação.

4.9.1.2. Regressão pelo método dos mínimos quadrados parciais (PLSR)

A avaliação da capacidade de modelagem e predição das curvas espectrais em relação a produtividade e concentração de K foliar, foram realizadas no software The Unscrambler® (CAMO Software - Norway) utilizando do espectro de reflectância de quase todos os tratamentos.

Nos tratamentos T-1, T-3 e T-4, cujo o dossel não estava fechado não coletou-se as curvas espectrais, os dados de produtividade e concentração de K para serem utilizados neste procedimento.

As curvas espectrais foram submetidas ao pré-tratamento aplicando o filtro Savitzky-Golay, conforme comentado no Tópico 4.8. Este procedimento foi necessário para evitar que possíveis ruídos nos dados influenciassem negativamente a qualidade do modelo ajustado.

Para construção do modelo, os dados foram divididos em dois grupos, sendo o primeiro, contendo 27 amostras (leituras espectrais) utilizados para calibração, e o segundo grupo contendo 9 amostras utilizados para validação do modelo PLSR obtido. Estas amostras foram selecionadas aleatoriamente no conjunto de dados, evitando tendências que poderia influenciar na qualidade do modelo.

Durante a etapa de calibração, a modelagem PLSR utiliza tanto a informação da matriz de dados X (dados espectrais) como da matriz de concentração Y (dados analíticos – K, produtividade), obtendo-se novas variáveis denominadas variáveis latentes ou fatores PLSR.

O melhor modelo de calibração é obtido através da escolha do número de variáveis latentes que apresentam os menores valores da raiz quadrada do erro médio (RMSE) e também maiores valores de R^2 .

A obtenção do RMSE foi realizada utilizando o método de validação cruzada onde n-1 amostras (curvas espectrais) foram retiradas para a calibração do modelo de predição. O erro obtido neste processo é representado por RMSEC e RMSECV, ou seja, os erros referentes a calibração (C) e validação cruzada (*Cross validation* – CV).

Como descrito anteriormente, a validação cruzada foi realizada a fim de se obter menores números de fatores PLSR que gerassem modelos com maiores R^2 e menores valores de RMSE, parâmetros estes que são indicadores da qualidade dos modelos. De acordo com Minasny e McBratney (2013), nos valores de $R^2 > 0,75$ os modelos apresentam excelente capacidade preditiva, $R^2 < 0,50$ temos modelos “não” confiáveis e valores de R^2 entre 0,75 e 0,50 os mesmos são considerados como confiáveis (razoáveis).

Após a obtenção do número de variáveis latentes consideradas ideais para a construção do modelo de predição, o mesmo foi validado utilizando o restante das curvas espectrais (9 amostras), que não participaram na construção do mesmo. Neste processo de validação, parâmetros como o RMSEP, Bias e R^2 , foram utilizados para avaliar a qualidade e precisão do modelo.

Ao final do procedimento os dados de produtividade e concentração de K nas plantas foram comparados com os valores de referência para interpretação e avaliação do potencial de utilização de dados espectrais como preditores para as variáveis de interesse.

5. RESULTADOS E DISCUSSÕES

5.1. Teste de comparação de médias para o teor de potássio foliar em milho

Antes da realização dos procedimentos estatísticos buscando avaliar o potencial de identificação dos tratamentos através dos IV's e também a modelagem em regressões visando a estimativa do teor foliar K, foi realizado o teste de comparação de médias para verificar se há alteração significativa dessa variável em função dos tratamentos estudados. Todas as datas de avaliações atenderam aos pressupostos básicos de normalidade dos resíduos e homogeneidade de variância, sendo posteriormente realizado o teste de Tukey ao nível de 5% de probabilidade de erro; os dados são mostrados na Tabela 3.

Observa-se que há ampla variação no teor foliar de K em todas as datas que foram realizadas as coletas para análise nutricional, sendo a menor média observada para o tratamento de extrema deficiência (T-3). Nota-se ainda que na data de 16/06 (R3) foi possível a separação de todos os tratamentos sendo que o tratamento padrão, ou seja, T-12 apresentou aproximadamente 7 vezes a mais a concentração de K em relação ao tratamento T-3. Outro importante ponto a ser observado, ocorrido em todas as datas, é a baixa concentração do nutriente no tratamento denominado de “fome oculta” (T-6) em relação ao T-12, sendo que em 08/05 (V12) e 16/06 (R3) o teor foliar está abaixo do recomendado, de acordo com a tabela de interpretação da EMBRAPA - Manual de análises químicas de solos, plantas e fertilizantes (2009), sendo considerado adequado, quando o teor foliar de K fique na faixa de 17 – 35 g kg⁻¹ para o estágio estádio reprodutivo.

Tabela 3. Teste de comparação de médias para o teor de K nas datas de avaliações de 17/04 (V7), 08/05 (V12) e 16/06 (R3).

Tratamentos	Média da concentração foliar de K (g kg ⁻¹)		
	17/04 (V7)	08/05 (V12)	16/06 (R3)
T-2	24,52 b	16,73 b	18,93 b
T-3	6,32 c	8,24 c	4,19 d
T-6	26,75 b	14,53 b	14,90 c
T-12	39,10 a	25,81 a	30,35 a
CV (%)	16,46	14,50	9,34
DMS	8,780	5,230	3,520

Médias seguidas por pelo menos uma mesma letra na coluna, não diferem estatisticamente entre si pelo teste de Tukey ao nível α de 5% de probabilidade de erro.

5.2. Comportamento espectral das plantas de milho em resposta aos níveis de K^+ no solo

O monitoramento remoto de nutrientes em plantas tem sido amplamente aplicado para o estudo do nitrogênio em diversas culturas agrícolas (MUÑOZ-HUERTA et al., 2013; GASPAROTTO et al., 2014), porém, poucos trabalhos buscaram a caracterização espectral da deficiência ocasionada pelo K. Entre estes, podemos citar os trabalhos avaliando a cultura do trigo (PIMSTEIN et al., 2011; MAHAJAN et al. 2014) do arroz (CHEN et al. 2014), da cana-de-açúcar (JACKSON et al., 1981) e em plantas de oliveiras (GOMEZ-CASERO et al., 2007).

A Figura 10 mostra as curvas espectrais obtidas com o espectrorradiômetro ASD Fieldspec 3 Jr. entre os diferentes tratamentos do experimento nas 9 datas de avaliação, sendo em V3, V5, V7, V8, V10, V12, R1, R3 e R5. Os tratamentos foram denominados como sendo: T-3 o tratamento de extrema deficiência, sem aplicação de K, T-6 o tratamento denominado como “fome oculta” e T-12 o tratamento submetido a melhor condição de desenvolvimento em relação à adubação.

Observa-se, na Figura 10, comportamento espectral bastante semelhante na primeira data de avaliação (V3) entre os tratamentos estudados, apresentando uma tendência pouco pronunciada para o T-3 de pequeno aumento na reflectância na região do azul (próximo a 450 nm) e no vermelho (próximo a 620 nm) do espectro eletromagnético.

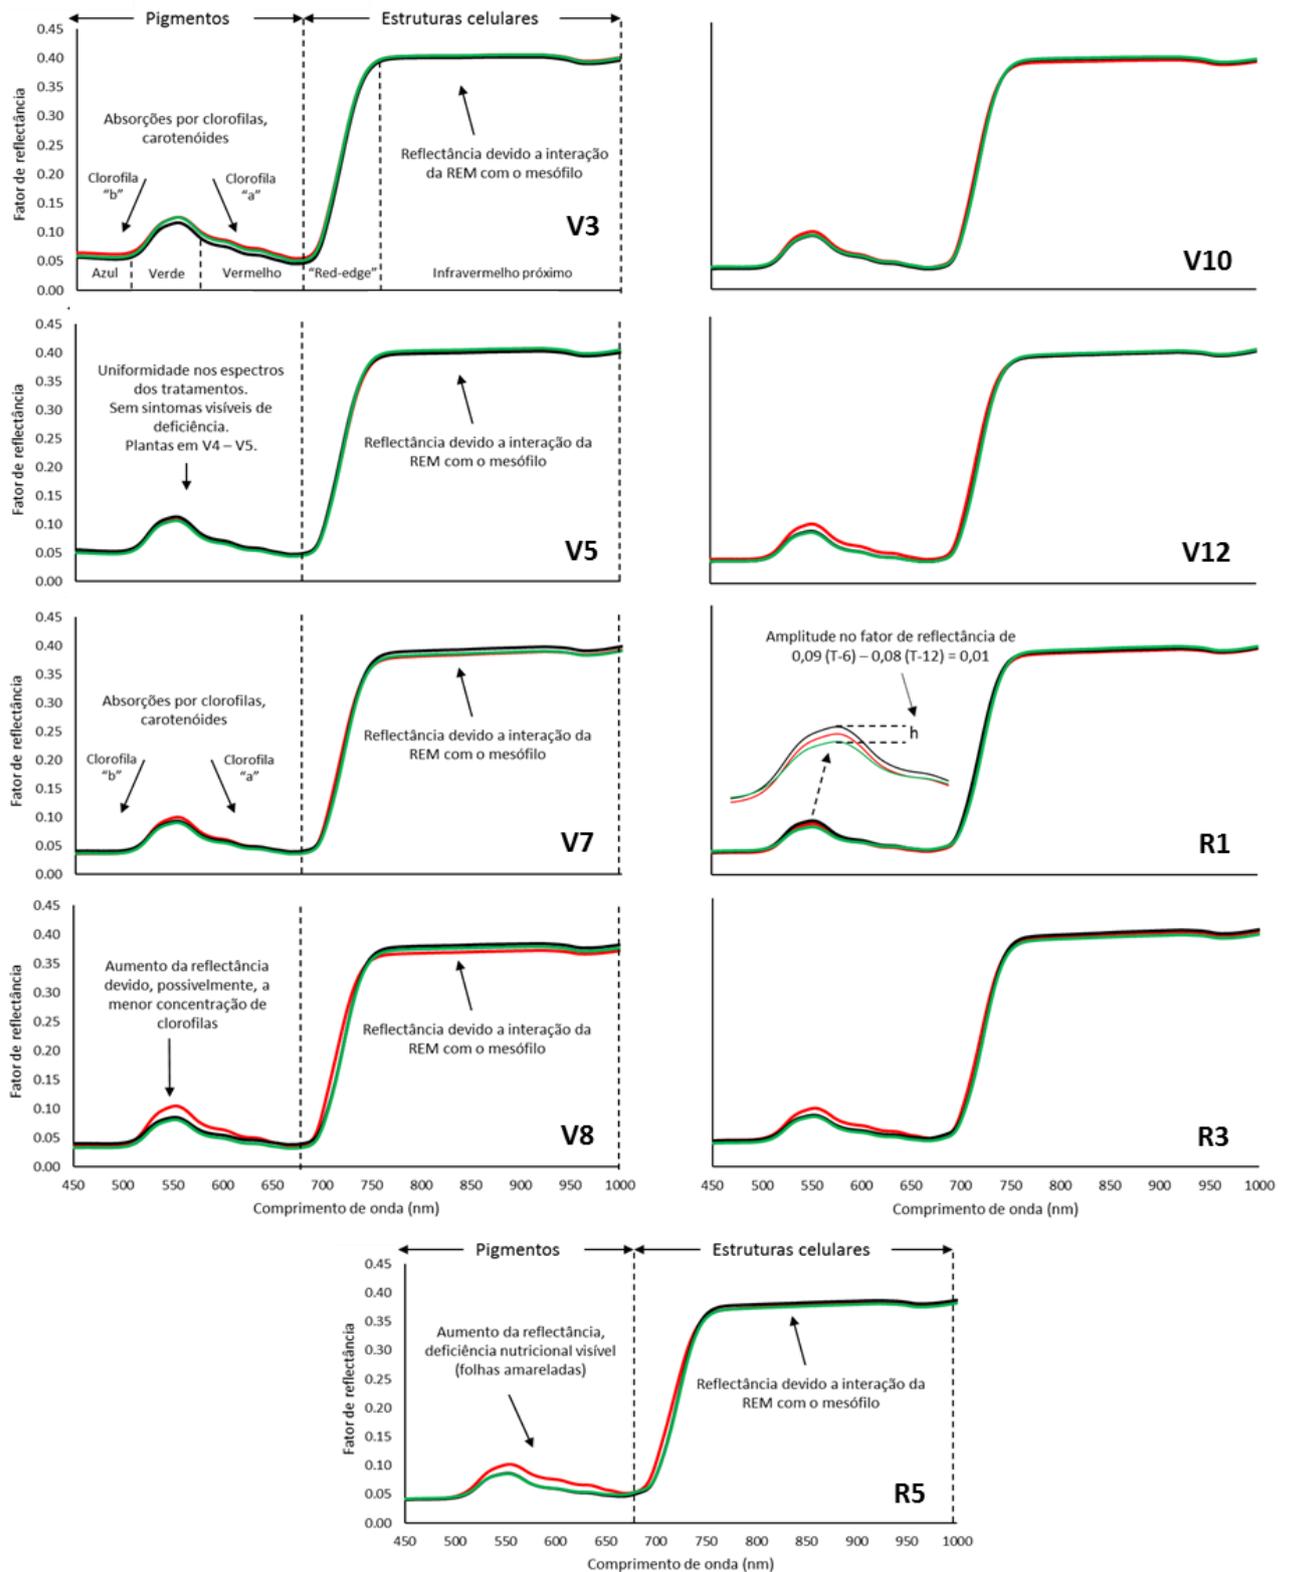


Figura 10 - Fator de reflectância médio das folhas de milho nos diferentes estádios de desenvolvimento avaliado.

Com o decorrer do desenvolvimento da cultura, as plantas impostas à condição limitante de desenvolvimento apresentaram aumento nesta amplitude no espectro de

reflectância, sendo observado os maiores valores para os estádios de desenvolvimento V7, V8, V10, V12, R3 e R5, sendo esta última data a que mais apresentou diferença na região do visível do espectro em relação aos demais tratamentos, devido a extrema condição de deficiência de K submetidas às plantas desenvolverem.

Quando analisado a região do infravermelho próximo, observou-se pequena diferença na reflectância em V8 para o tratamento T-3. Esta região do espectro é marcada pela reduzida absorção da REM e amplo espalhamento interno no mesófilo foliar, devido a múltiplas reflexões da luz com as paredes celulares hidratadas das folhas. Além disso, quanto mais lacunosa for a estrutura interna foliar, maior será o espalhamento interno da radiação incidente, conseqüentemente, maior a reflectância.

Diante disso, possivelmente as plantas destes tratamentos estavam sofrendo com a condição limitante de desenvolvimento imposta pela deficiência de K. Como o K participa na regulação osmótica, atuando diretamente no mecanismo de fechamento e abertura dos estômatos, a deficiência prejudica significativamente a eficiência dos processos bioquímicos que envolvem a utilização da água pela planta, contribuindo, provavelmente, para a diminuição da reflectância na região do infravermelho próximo nesta data de avaliação.

Outra provável explicação seria de que as que plantas deficientes apresentam tecidos menos enrijecidos, como consequência da menor espessura da cutícula e da parede celular, menor formação de tecidos esclerenquimáticos, parenquimáticos, menor espaços intercelulares (PERRENOUD, 1990), tornando menos lacunosa a estrutura foliar interna.

Bauer (1975), relata que em plantas cuja folhas apresentam deficiência em fósforo e cálcio, a absorção da REM na região do infravermelho próximo é menor do que a de folhas sem a deficiência. Por outro lado, em folhas deficientes em enxofre, magnésio, potássio e nitrogênio, a absorção é maior do que em folhas sadias, portanto, a reflectância nesta faixa do espectro é menor.

Porém, não foi possível observar esta tendência no comportamento espectral dos tratamentos para essa faixa do espectro, sendo nas demais datas de avaliação, as respostas espectrais entre os tratamentos praticamente idênticas.

Por apresentarem fortes absorção da REM na região do visível, especialmente nas regiões do azul e vermelho, as moléculas de clorofilas e outros pigmentos constituintes das folhas promovem alterações na resposta espectral somente nesta região, sendo as clorofilas “a” e “b” os pigmentos que mais marcam o comportamento espectral. Já na região verde do espectro, tais pigmentos absorvem pequena fração da REM, ocasionando no aumento da

reflectância neste intervalo espectral, sendo caracterizado pela tonalidade verde observada pela visão humana.

Embora o íon K não seja constituinte das moléculas de clorofilas, a falta deste elemento promove a destruição das mesmas, indicando que ocorre a participação do K como precursor na formação de clorofila e/ou prevenindo a decomposição (FAGERIA e GHEYI, 1999). Devido a condição limitante de desenvolvimento, o aparato fotossintético possivelmente já apresentava limitações na síntese destas estruturas e capacidade fotossintetizante, sendo refletida esta característica em alterações nas regiões do verde, vermelho e azul do espectro eletromagnético, portanto ocorrendo aumento na reflectância nessas faixas espectrais.

Hoffer (1978), relata que a produção de clorofila é reduzida quando a planta está sob condições de estresse, promovendo a redução da absorção da REM e conseqüentemente aumentando a reflectância na região do visível, especialmente na região do comprimento de onda da verde, resultando na coloração amarelada das folhas sob estresse. Esta característica de amarelecimento foi observada durante a condução do experimento, principalmente no estágio de desenvolvimento reprodutivo R5, conforme visualizado na Figura 11.



Figura 11 - Folhas de milho com coloração amarelada, possivelmente, decorrente da redução da concentração de clorofila nas folhas.

Gasparotto (2014) trabalhando com doses de N na cultura do milho observou aumento na reflectância especialmente na região visível conforme a disponibilidade do nutriente era diminuída, sendo a testemunha sem adubação a que apresentou a maior amplitude espectral aos 80 DAE.

Ponzoni (2001) relata que plantas submetidas a condições de estresses como doenças, distúrbios fisiológicos e condições adversas, promove aumento da reflectância na região do visível, quando comparadas a folhas de uma vegetação sadia. Esta mesma característica foi observada por Ponzoni e Gonçalves (1999), onde os mesmos relataram que a

deficiência promovida pelo K diferiram espectralmente na região do visível em folhas de eucalipto, tornando passível de ser detectado.

Gomez-Casero et al., (2007), trabalhando com deficiência de K em oliveiras concluíram que, a relação entre a concentração deste elemento nas folhas e as medidas espectrais torna possível a discriminação das plantas com deficiência em relação as plantas sem a deficiência.

5.3. Avaliação da relação entre índices de vegetação obtidos por meio do espectrorradiômetro, câmeras digitais e o sensor AisaFENIX, com os tratamentos estudados

5.3.1. Índices de vegetação obtido pelo espectrorradiômetro a nível de folha

Conforme comentado no Tópico 3.5, os IV's têm por finalidade realçar o comportamento espectral da vegetação em relação a outros alvos de interesse. Objetivando encontrar diferenças entre os tratamentos estudados, procedeu-se a análise estatística para os IV's NDVI, GNDVI, GNIR, RNIR, RVI e GRVI, através de teste de comparação de médias pelo teste de Tukey ao nível α de 5% de probabilidade de erro.

Antes do teste de comparação de pares de médias, foram realizados os testes de pressuposições básicas para verificação da homocedasticidade de variâncias e normalidade dos resíduos, utilizando o teste de Bartlett e Shapiro-Wilk, respectivamente.

Apenas os IV's que atingiram a significância em ambos os testes foram submetidos ao teste de comparações múltiplas de Tukey. Optou-se em não transformação para os que não atingiram a não-significância.

Devido as características de operação e modo de aquisição de dados do sensor, foi possível obter o espectro de reflectância do tratamento T-2, T-3, T-6 e T-12 a partir do espectrorradiômetro e das câmeras digitais, sendo posteriormente gerados os IV's para avaliação estatística.

Na Tabela 4 e 5 estão os resultados dos testes de homogeneidade de variâncias e normalidade dos erros para os estádios de desenvolvimento avaliados referentes aos índices de vegetação obtido pelo espectrorradiômetro.

Tabela 4. Teste de normalidade dos erros de Shapiro-Wilk para os índices de vegetação obtido pelo espectrorradiômetro.

Índices de Vegetação	Estádios de desenvolvimento								
	Vegetativo						Reprodutivo		
	V3	V5	V7	V8	V10	V12	R1	R3	R5
NDVI	0,126 ^{ns}	0,864 ^{ns}	0,292 ^{ns}	0,786 ^{ns}	0,941 ^{ns}	0,521 ^{ns}	0,227 ^{ns}	0,412 ^{ns}	0,276 ^{ns}
GNDVI	0,886 ^{ns}	0,939 ^{ns}	0,422 ^{ns}	0,468 ^{ns}	0,843 ^{ns}	0,709 ^{ns}	0,963 ^{ns}	0,678 ^{ns}	0,171 ^{ns}
GNIR	0,899 ^{ns}	0,914 ^{ns}	0,399 ^{ns}	0,493 ^{ns}	0,841 ^{ns}	0,684 ^{ns}	0,971 ^{ns}	0,707 ^{ns}	0,162 ^{ns}
RNIR	0,125 ^{ns}	0,888 ^{ns}	0,289 ^{ns}	0,801 ^{ns}	0,944 ^{ns}	0,519 ^{ns}	0,217 ^{ns}	0,402 ^{ns}	0,235 ^{ns}
RVI	0,100 ^{ns}	0,720 ^{ns}	0,318 ^{ns}	0,509 ^{ns}	0,919 ^{ns}	0,531 ^{ns}	0,352 ^{ns}	0,423 ^{ns}	0,588 ^{ns}
GRVI	0,803 ^{ns}	0,835 ^{ns}	0,517 ^{ns}	0,347 ^{ns}	0,861 ^{ns}	0,811 ^{ns}	0,969 ^{ns}	0,519 ^{ns}	0,142 ^{ns}

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

Tabela 5. Teste de homogeneidade de variância de Bartlett para os índices de vegetação obtido pelo espectrorradiômetro.

Índices de Vegetação	Estádios de desenvolvimento								
	Vegetativo						Reprodutivo		
	V3	V5	V7	V8	V10	V12	R1	R3	R5
NDVI	0,032 *	0,267 ^{ns}	0,671 ^{ns}	0,310 ^{ns}	0,100 ^{ns}	0,754 ^{ns}	0,940 ^{ns}	0,973 ^{ns}	0,730 ^{ns}
GNDVI	0,625 ^{ns}	0,353 ^{ns}	0,191 ^{ns}	0,845 ^{ns}	0,291 ^{ns}	0,559 ^{ns}	0,158 ^{ns}	0,838 ^{ns}	0,993 ^{ns}
GNIR	0,610 ^{ns}	0,348 ^{ns}	0,191 ^{ns}	0,838 ^{ns}	0,284 ^{ns}	0,568 ^{ns}	0,170 ^{ns}	0,834 ^{ns}	0,978 ^{ns}
RNIR	0,030 *	0,259 ^{ns}	0,670 ^{ns}	0,298 ^{ns}	0,098 ^{ns}	0,753 ^{ns}	0,949 ^{ns}	0,970 ^{ns}	0,723 ^{ns}
RVI	0,040 *	0,326 ^{ns}	0,669 ^{ns}	0,427 ^{ns}	0,118 ^{ns}	0,766 ^{ns}	0,836 ^{ns}	0,987 ^{ns}	0,718 ^{ns}
GRVI	0,665 ^{ns}	0,311 ^{ns}	0,190 ^{ns}	0,867 ^{ns}	0,311 ^{ns}	0,516 ^{ns}	0,106 ^{ns}	0,848 ^{ns}	0,928 ^{ns}

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

Observa-se que os IV's NDVI, RNIR e RVI em V3 apresentou resultado significativo para o teste de Bartlett. Por outro lado, o teste de Shapiro-Wilk demonstrou não significância para todos os índices e todas as datas avaliadas, não podendo, portanto, prosseguir na análise de variância (ANOVA).

Apenas nos estádios de desenvolvimento V10, V12, V7 e V8 apresentaram significância pelo teste F da ANOVA para o efeito de tratamento e para pelo menos um IV estudado. Porém, apenas em V8 o teste de Tukey apresentou sensibilidade suficiente para diferenciar o tratamento T-3 em relação aos demais, para os IV's GNIR, GNDVI e GRVI (Tabela 6). Este resultado, teoricamente, era de ser esperado, pois é possível visualizar

aumento na reflectância (Tópico 5.2) na região verde do espectro para este tratamento, sendo sensível apenas os IV's que utilizam esta banda espectral.

Coelho e Alves (2004), relatam que a absorção de K é máxima durante este estágio, com elevada taxa de acúmulo nos primeiros 30 a 40 dias de desenvolvimento, o que sugere que o nutriente deve estar disponível para as plantas na fase inicial de desenvolvimento.

Nas demais avaliações (Tabela 6), observa-se a alta similaridade entre os valores dos IV's em relação aos tratamentos estudados. Possivelmente com o aumento do número de leituras espectrais das folhas e, conseqüentemente, o aumento da representatividade na parcela experimental, almeja-se que diferenças estatisticamente significantes entre os tratamentos sejam passíveis de serem identificadas por meio dos IV's, principalmente para a condição de extrema deficiência por K.

Tabela 6. Teste de comparação de médias dos índices de vegetação obtido pelo espectrorradiômetro, significativo pelo teste F da ANOVA.

Índices de Vegetação	Tratamentos	Médias dos índices de vegetação			
		Estádios de desenvolvimento			
		V7	V8	V10	V12
NDVI	T-2	0,800 a	0,814 a	0,800 abc	0,807 ab
	T-3	0,794 a	0,782 ab	0,800 abc	0,782 ab
	T-6	0,797 a	0,796 ab	0,809 ab	0,806 ab
	T-12	0,805 a	0,819 a	0,802 abc	0,808 ab
GNDVI	T-2	0,633 a	0,658 a	0,629 a	0,642 ab
	T-3	0,604 a	0,577 b	0,612 ab	0,604 bcd
	T-6	0,632 a	0,647 a	0,634 a	0,641 ab
	T-12	0,634 a	0,658 a	0,633 a	0,649 ab
GNIR	T-2	0,225 a	0,206 b	0,227 a	0,218 bc
	T-3	0,248 a	0,268 a	0,240 ab	0,247 ab
	T-6	0,225 a	0,214 b	0,223 a	0,219 bc
	T-12	0,224 a	0,206 b	0,224 a	0,213 bc
RNIR	T-2	0,111 a	0,102 b	0,110 abc	0,107 ab
	T-3	0,115 a	0,122 ab	0,110 abc	0,122 ab
	T-6	0,113 a	0,113 ab	0,105 bc	0,107 ab
	T-12	0,108 a	0,099 b	0,109 abc	0,106 ab
RVI	T-2	9,105 a	9,800 a	9,123 abc	9,352 ab
	T-3	8,748 ab	8,210 ab	9,091 abc	8,396 ab
	T-6	8,867 a	8,859 ab	9,518 ab	9,349 ab
	T-12	9,356 a	10,071 a	9,160 abc	9,448 ab
GRVI	T-2	4,475 a	4,859 a	4,422 a	4,586 abc
	T-3	4,089 a	3,730 b	4,168 ab	4,099 bcd
	T-6	4,443 a	4,674 a	4,478 a	4,571 abc
	T-12	4,481 a	4,858 a	4,462 a	4,700 ab

¹Médias seguidas por pelo menos uma mesma letra na coluna, não diferem estatisticamente entre si pelo teste Tukey ao nível α de 5% de probabilidade de erro. ²O maior coeficiente de variação observado foi de 9.41% e o menor 1.51%.

Embora visualmente é possível observar diferenças no espectro de reflectância (Tópico 5.2), principalmente na região verde e vermelho em outras datas de avaliações, sendo observado grande aumento na amplitude do espectro no tratamento T-3 para o estágio de desenvolvimento reprodutivo R5, o mesmo não diferiu estatisticamente pelo teste de F da ANOVA e também no Teste Tukey, em relação aos demais tratamentos. Esta não-

significância possivelmente pode ser explicada decorrente da grande heterogeneidade entre as plantas, principalmente foliar, onde as leituras espectrais apresentaram muita variação e, conseqüentemente, quando submetidas à análise estatística, apresentaram o maior coeficiente de variação entre todas as avaliações.

5.3.2. Índices de vegetação obtido pelo sensor imageador hiperespectral AisaFENIX

Na Tabela 7, encontra-se os resultados da análise de normalidade e homogeneidade de variâncias referentes aos IV's obtido pelo sensor AisaFENIX no estágio de desenvolvimento vegetativo V7. Todos os IV's atenderam os pressupostos básicos da ANOVA e significância pelo teste F, podendo, portanto, prosseguir para o teste de comparação múltipla de médias pelo teste de Tukey.

Não foi possível obter o espectro de reflectância do tratamento T-3 devido a contaminação dos pixels da vegetação com o solo. Sendo assim, buscando a confiabilidade dos dados, optou-se pela não utilização deste tratamento para a geração dos IV's. A análise estatística de comparação de médias foi realizada nos tratamentos T-2, T-6 e T-12 (Tabela 8).

De maneira análoga, não se observou diferença entre os tratamentos estudados para todos os IV's testado pelo teste de Tukey. Observa-se a alta similaridade no valor de média dos IV's para todos os tratamentos, mesmo o coeficiente de variação sendo muito pequeno e a diferença mínima significativa (DMS) pelo teste de Tukey sendo de igual grandeza, não foi possível visualizar diferenças estatísticas.

Apesar dos IV's serem gerados através da média de quase toda a totalidade de pixels de cada parcela experimental, aumentando a representatividade e homogeneidade entre as repetições, este resultado obtido, assim como os resultados do espectrorradiômetro ASD FieldSpec 3 Jr., indicam que os IV's possuem potencial limitado de diferenciação quando as plantas são submetidas a condições "intermediárias" de suprimento de K, neste caso representado pelo tratamento T-6.

Tabela 7. Teste de homogeneidade de variâncias e normalidade dos erros para os índices de vegetação obtido pelo sensor AisaFENIX.

Estádio de desenvolvimento V7		
Índices de Vegetação	Shapiro-Wilk	Bartlett
NDVI	0,262 ^{ns}	0,953 ^{ns}
GNDVI	0,232 ^{ns}	0,994 ^{ns}
GNIR	0,227 ^{ns}	0,993 ^{ns}
RNIR	0,277 ^{ns}	0,953 ^{ns}
RVI	0,236 ^{ns}	0,924 ^{ns}
GRVI	0,253 ^{ns}	0,992 ^{ns}

^{ns} Não significativa (p-valor > 0,05).

Tabela 8. Teste de comparação de médias dos índices de vegetação obtido pelo sensor AisaFENIX.

Tratamentos	Médias dos índices de vegetação					
	NDVI	GNDVI	GNIR	RNIR	RVI	GRVI
T-2	0,700 ab	0,696 ab	0,179 ab	0,176 ab	5,691 ab	5,586 ab
T-6	0,705 ab	0,698 ab	0,178 ab	0,173 ab	5,812 ab	5,623 ab
T-12	0,735 a	0,708 a	0,171 b	0,153 b	6,596 a	5,845 a
CV (%)	2,39	1,06	2,87	6,80	6,89	2,87
DMS	0,041	0,018	0,012	0,028	0,976	0,387

Médias seguidas por pelo menos uma mesma letra na coluna, não diferem estatisticamente entre si pelo teste Tukey ao nível α de 5% de probabilidade de erro.

5.3.3. Índices de vegetação obtido por câmeras digitais

5.3.3.1. Conversão do número digital para reflectância

Câmeras digitais modernas são constituídas com sistema de efeito *gamma* o qual realiza o mapeamento da imagem baseado na radiação incidente no sensor fornecendo valores de *output* que simulam o olho humano, melhorando, assim, a qualidade visual da imagem obtida (WITHAGEN et al., 2007; CRUSIOL et al., 2017).

Este efeito atribui-se que se um determinado *pixel* o recebeu o dobro de radiância, o mesmo deveria apresentar o dobro do valor do ND. Porém, para o olho humano, um objeto que fornece o dobro de radiância não será visualizado com o dobro de brilho. Dessa forma, o efeito *gamma* simula o comportamento do olho humano e, por essa razão, a relação linear

entre radiância e número digital é afetada (GEHRKE e GREIWE, 2014) podendo resultar em comportamento não linear (RITCHIE et al., 2008).

A partir deste conhecimento, há necessidade de adequação de um modelo que melhor descreva o comportamento dos dados (WITHAGEN et al., 2007), sendo escolhido o modelo exponencial (não linear), logaritmo e quadrático (polinomial) para conversão dos valores de número digital para reflectância, conforme mostrado nas equações:

A.
$$\hat{y} = 0,05280 \times e^{-0,01390 \times ND}$$

B.
$$\hat{y} = -2,68724708 + 0,613383536 \times \text{Ln}(ND)$$

C.
$$\hat{y} = -10,4328918 + 0,172106012 \times ND - 0,00055304 \times ND^2$$

onde:

A = modelo de regressão exponencial para conversão do ND em reflectância para banda vermelha.

B = modelo de regressão logarítmica para conversão do ND em reflectância para banda verde.

C = modelo de regressão quadrática para conversão do ND em reflectância para banda do infravermelho próximo.

ND = número digital das imagens das câmeras digitais nos tratamentos desejados.

Importante ressaltar que buscou-se o ajuste de modelos de regressão que melhor atendesse o comportamento dos dados e parâmetros estatísticos para avaliar a qualidade de ajuste, sendo todos os modelos significantes pelo teste F e todos os coeficientes de regressão significantes pelo teste “t” ao nível de 5% de probabilidade de erro. A correlação de Pearson foi superior a 0,97 entre as câmeras digitais utilizadas e o espectrorradiômetro em solo, indicando que os dados das câmeras, estatisticamente, podem ser convertidos para reflectância para a geração dos IV’s.

Com relação ao efeito *vignetting*, Kelcey e Lucieer (2012) relatam que interferências radiométricas no fotossensor CCD podem causar diminuição nos valores do ND às bordas das imagens, podendo produzir valores de pixels não condizente com os valores ao centro da imagem. Porém, a correção do mesmo também pode causar alterações na resposta radiométrica das imagens (LALIBERTE et al., 2011). Deste modo, optou-se pela não correção das imagens visto que as câmeras digitais utilizadas foram submetidas a esfera

integradora para determinação da variação dos ND, sendo concluído que os valores dos pixels de ambas as câmeras apresentam homogeneidade - A metodologia utilizada e dados de variância dos pixels estão disponível no trabalho de Crusiol et al., (2016), disponível em <http://www.tandfonline.com/doi/abs/10.1080/01431161.2016.1264032>.

Nas Tabelas 9 e 10, encontram-se os resultados dos testes de normalidade dos erros e homogeneidade das variâncias para os IV's gerados a partir dos dados das imagens das câmeras digitais acopladas ao VANT.

As avaliações realizadas nos estádios de desenvolvimento V3 e V5 foram excluídas da análise devido a contaminação dos pixels da vegetação com o solo.

Observa-se que em V7 apenas o índice de vegetação RVI apresentou não-significância para ambos testes de pressuposição básica da ANOVA. Para V8, apenas o GRVI não atendeu a homogeneidade para o teste de Bartlett. De maneira análoga foi observado para o índice RNIR no estádio V10. Em V12, NDVI e RNIR para ambos testes. Já para o estádio reprodutivo R1, apenas o índice RVI atendeu ao teste de Shapiro-Wilk, por outro lado, o teste de Bartlett foi atendido para todos os IV testados. EM R3 todos os IV's passaram aos testes utilizados. No último estádio avaliado, os índices NDVI e RNIR não foram atendidos ao teste de normalidade dos resíduos de Shapiro-Wilk.

Tabela 9. Teste de homogeneidade de variâncias e normalidade dos erros para os índices de vegetação obtido por câmeras digitais acopladas ao VANT.

Índices de Vegetação	Estádios de desenvolvimento						
	Vegetativo				Reprodutivo		
	V7	V8	V10	V12	R1	R3	R5
NDVI	0,095 ^{ns}	0,942 ^{ns}	0,767 ^{ns}	0,001 [*]	0,017 [*]	0,923 ^{ns}	0,016 [*]
GNDVI	0,001 [*]	0,867 ^{ns}	0,406 ^{ns}	0,486 ^{ns}	0,009 [*]	0,556 ^{ns}	0,091 ^{ns}
GNIR	0,001 [*]	0,795 ^{ns}	0,405 ^{ns}	0,458 ^{ns}	0,008 [*]	0,521 ^{ns}	0,070 ^{ns}
RNIR	0,045 [*]	0,953 ^{ns}	0,656 ^{ns}	0,001 [*]	0,016 [*]	0,933 ^{ns}	0,023 [*]
RVI	0,430 ^{ns}	0,947 ^{ns}	0,483 ^{ns}	0,159 ^{ns}	0,052 ^{ns}	0,880 ^{ns}	0,102 ^{ns}
GRVI	0,026 [*]	0,360 ^{ns}	0,853 ^{ns}	0,952 ^{ns}	0,034 [*]	0,729 ^{ns}	0,564 ^{ns}

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

Tabela 10. Teste de homogeneidade de variância de Bartlett para os índices de vegetação obtido pelo espectrorradiômetro.

Índices de Vegetação	Estádios de desenvolvimento						
	Vegetativo				Reprodutivo		
	V7	V8	V10	V12	R1	R3	R5
NDVI	0,012 *	0,715 ^{ns}	0,064 ^{ns}	0,001 *	0,489 ^{ns}	0,481 ^{ns}	0,580 ^{ns}
GNDVI	0,045 *	0,477 ^{ns}	0,800 ^{ns}	0,455 ^{ns}	0,746 ^{ns}	0,789 ^{ns}	0,636 ^{ns}
GNIR	0,035 *	0,528 ^{ns}	0,786 ^{ns}	0,468 ^{ns}	0,714 ^{ns}	0,779 ^{ns}	0,633 ^{ns}
RNIR	0,006 *	0,662 ^{ns}	0,049 *	0,001 *	0,472 ^{ns}	0,447 ^{ns}	0,550 ^{ns}
RVI	0,305 ^{ns}	0,395 ^{ns}	0,590 ^{ns}	0,142 ^{ns}	0,768 ^{ns}	0,786 ^{ns}	0,605 ^{ns}
GRVI	0,212 ^{ns}	0,028 *	0,754 ^{ns}	0,104 ^{ns}	0,986 ^{ns}	0,770 ^{ns}	0,202 ^{ns}

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

Na Tabela 11 encontram-se os resultados do teste de comparação de médias de Tukey para os IV's gerados por meio de câmeras digitais acopladas ao VANT.

De modo geral os IV's que utilizam a banda do vermelho do espectro foram os que mais apresentaram sensibilidade para diferenciação do tratamento com deficiência de K (T-3) em relação aos demais, porém, nenhum IV's em nenhuma data de avaliação apresentou sensibilidade suficiente para a diferenciação do tratamento denominado como "fome oculta" (T-6).

Quando comparados os IV's no mesmo estágio de desenvolvimento (V8) entre o espectrorradiômetro em solo e as câmeras digitais acopladas ao VANT, observou-se que apenas os IV's que utilizam a banda verde apresentaram diferença significativa para o T-3 em relação aos demais tratamentos estudados, diferentemente quando obtidos pelas câmeras digitais. Outro importante ponto a ser observado, é a diferença entre as médias dos tratamentos entre os dois sensores, onde nos IV's obtidos pelas câmeras digitais ocorreram maiores divergência nas médias para os tratamentos, especialmente para o T-3 obtendo, portanto, diferenças significantes para o mesmo.

Devido a qualidade dos modelos de conversão e altíssima resolução espacial obtida por este sistema acoplado ao VANT, foi possível obter a informação, a nível de pixel, de quase a totalidade da parcela experimental, refletindo em baixíssimos coeficientes de variação, diferentemente do espectrorradiômetro onde a representatividade da condição experimental é limitada ao número de leituras espectrais realizada e a operacionalização do equipamento.

Observa-se que a faixa de valores para os IV's NDVI e GNDVI oscilaram entre 0,80 e 0,91. A vegetação sadia em pleno vigor vegetativo, apresenta menor reflectância na faixa do espectro visível e alta reflectância no infravermelho próximo, conseqüentemente exibindo valores maiores destes índices quando comparados a plantas submetidas a estresse. Por outro lado, plantas estressadas apresentam aumento na reflectância na região do visível e diminuição no infravermelho próximo, resultando na diminuição do valor dos IV's que utilizam tais bandas espectrais.

Embora o IV GNDVI apresente uma escala dinâmica maior do que a do NDVI, sendo considerado, em média, pelo menos cinco vezes mais sensível (GITELSON et al., 1996), observou-se que, neste estudo, o NDVI apresentou maior sensibilidade e potencial para diferenciar o tratamento com severa deficiência (T-3). Porém, nenhum IV's diferiram estatisticamente para o tratamento padrão (T-12) e o denominado "fome oculta" (T-6), em todas as datas de avaliação.

Gomez-Casero et al., (2007), obtiveram resultados semelhantes trabalhando em plantas de oliveira submetidas a condição de deficiência de K por dez anos. Os autores obtiveram os melhores resultados de discriminação dos tratamentos quando utilizado o IV NDVI. Neste mesmo trabalho, concluíram que determinados comprimentos de onda na região visível (verde e vermelho) e alguns mais na região NIR podem ser úteis para diferenciar esses tratamentos. De maneira análoga Severtson et al., (2016) concluíram que o IV NDVI, obtido por uma câmera multiespectral acoplada ao VANT, apresentou o menor valor quando plantas de canola são submetidas a condição de deficiência por K.

Coomer Taylor (2016), relata que o NDVI em plantas de algodão deficientes em K apresenta ótima correlação com teor deste nutriente na folha, nos estádios iniciais de desenvolvimento da planta.

Com relação aos IV's GNIR e RNIR, que são produtos de razões simples entre bandas do espectro visível e a banda do infravermelho próximo apresentando uma relação inversa, sua principal característica, quando estudado em plantas mal nutridas, é por apresentarem maiores valores do que plantas nutricionalmente equilibradas.

Porém, esta característica não foi observada para o GNIR em V8 e V10, sendo notado que o tratamento com maior vigor vegetativo (T-12) apresentou maior valor deste IV.

Por outro lado, nos demais estádios avaliados observou-se normalidade do comportamento do mesmo, sendo o T-3 exibindo maiores valores em relação aos demais

tratamentos, sendo novamente possível a distinção do tratamento mais deficiente em relação aos demais com base na utilização de IV's obtidos por câmeras digitais acopladas ao VANT.

Tabela 11. Teste de comparação de médias dos índices de vegetação obtido por câmeras digitais acopladas ao VANT.

Índices de Vegetação	Tratamentos	Estádios de desenvolvimento						
		Vegetativo				Reprodutivo		
		V7	V8	V10	V12	R1	R3	R5
NDVI	T-2	-	0,87 a	0,90 a	-	-	0,89 a	-
	T-3	-	0,81 b	0,86 b	-	-	0,86 b	-
	T-6	-	0,87 a	0,90 a	-	-	0,89 a	-
	T-12	-	0,86 a	0,89 a	-	-	0,89 a	-
GNDVI	T-2	-	0,82 b	0,87 ab	0,88 ab	-	0,87 a	0,91 a
	T-3	-	0,83 ab	0,88 a	0,86 b	-	0,84 b	0,87 b
	T-6	-	0,82 b	0,88 ab	0,89 a	-	0,87 a	0,91 ab
	T-12	-	0,81 b	0,84 b	0,90 a	-	0,87 a	0,91 a
GNIR	T-2	-	0,10 a	0,07 b	0,06 ab	-	0,07 b	0,04 b
	T-3	-	0,09 ab	0,06 ab	0,07 a	-	0,09 a	0,07 a
	T-6	-	0,10 a	0,07 ab	0,06 b	-	0,07 b	0,05 ab
	T-12	-	0,10 a	0,09 a	0,05 b	-	0,07 b	0,05 b
RNIR	T-2	-	0,07 b	-	-	-	0,06 b	-
	T-3	-	0,10 a	-	-	-	0,08 a	-
	T-6	-	0,07 b	-	-	-	0,06 b	-
	T-12	-	0,07 b	-	-	-	0,06 b	-
RVI	T-2	11,58 a	14,36 a	19,35 a	20,48 a	19,03 a	16,54 a	15,74 ab
	T-3	7,57 b	9,64 b	13,85 b	13,56 b	18,17 a	12,95 b	10,65 b
	T-6	11,44 a	14,51 a	19,87 a	20,65 a	19,63 a	16,82 a	14,83 ab
	T-12	12,34 a	13,78 a	17,79 a	21,01 a	17,68 a	16,60 a	15,75 ab
GRVI	T-2	-	-	14,55 ab	16,37 ab	-	14,29 ab	23,23 ab
	T-3	-	-	16,05 a	13,50 b	-	11,46 b	15,31 b
	T-6	-	-	15,40 ab	17,45 ab	-	14,34 a	20,75 ab
	T-12	-	-	11,78 b	19,98 a	-	14,56 a	23,77 ab

¹Médias seguidas por pelo menos uma mesma letra na coluna, não diferem estatisticamente entre si pelo teste Tukey ao nível α de 5% de probabilidade de erro. ²O maior coeficiente de variação observado foi de 16.84% e o menor 0.69%.

Por se tratar de um nutriente que apresenta participação “secundária” na síntese de compostos celulares, a simples relação de bandas espectrais (IV's) não apresenta sensibilidade

suficiente para discriminação entre a condição “intermediária” (T-6) e ótima (T-12) de suprimento deste elemento, diferentemente dos resultados obtidos quando avaliado para o nitrogênio, onde os IV’s apresentam elevada capacidade em detectar diferenças significantes quando aplicado em diferentes doses nos tratamentos (GASPAROTTO, 2014; OSBOURNE et al., 2007; JAIN et al., 2007) devido à participação direta na síntese das moléculas de clorofilas (LIMA et al., 2001), resultando em alterações marcantes no espectro de reflectância.

Esta característica reforça a necessidade em buscar novas técnicas para análises de dados espectrais, utilizando de todo o espectro de reflectância, a fim de identificar feições específicas deste elemento em culturas que ainda não foram explorados os estudos em termos de outros nutrientes, a não ser o nitrogênio.

Porém, com os resultados obtidos, é possível o acompanhamento e monitoramento da deficiência de K em milho a partir dos IV’s durante o ciclo de desenvolvimento da planta, sendo marcante as diferenças, em termos de médias, entre as plantas com deficiência em relação a condição ótima de suprimento deste elemento.

5.4. Comportamento espectral obtido pelo sensor imageador hiperespectral AisaFENIX

Na Figura 12 encontra-se o espectro de reflectância obtido pelo sensor imageador hiperespectral AisaFENIX dos tratamentos no estágio de desenvolvimento V7.

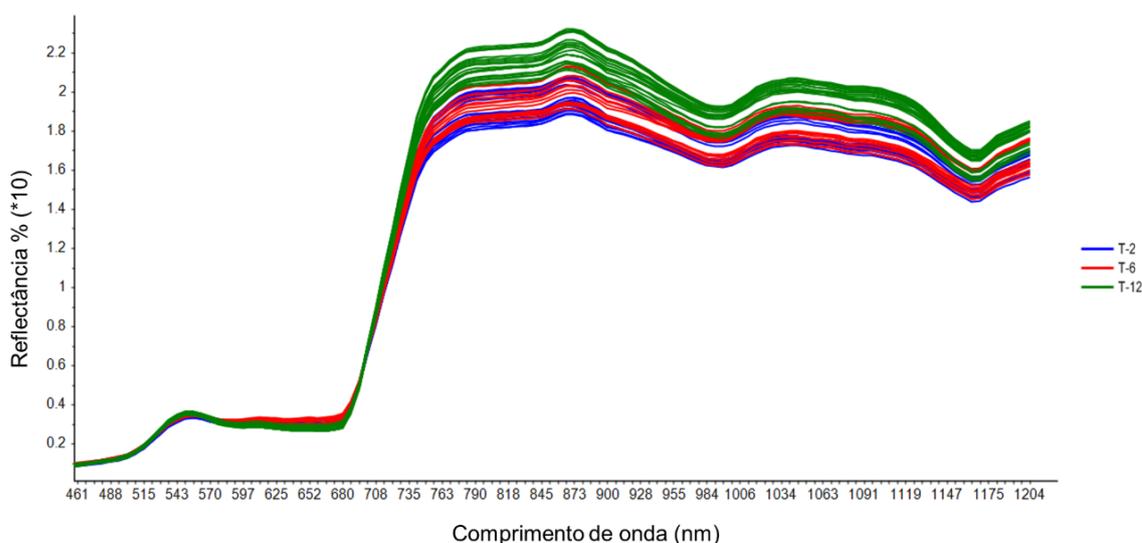


Figura 12 - Distribuição das curvas espectrais obtidas pelo sensor hiperespectral AisaFENIX nos tratamentos T-2, T-6 e T-12.

Observa-se diferenças na reflectância entre o T-2, o T-6 e o considerado como o padrão (T-12), ou seja, o mais bem adubado no experimento. Devido a extrema condição de deficiência do tratamento T-3, não foi possível a obtenção da resposta espectral das plantas devido a interferência espectral pelo solo, deste modo analisou-se o espectro de reflectância do segundo tratamento com menor disponibilidade de K^+ (T-2).

Nota-se que na região do azul e verde não há evidências de diferenças entre os espectros dos tratamentos. Por outro lado, o T-6 apresentou leve tendência de aumento da reflectância na região vermelha, provavelmente decorrente da redução da concentração de clorofilas.

Com relação a região do infravermelho próximo, é possível observar nítidas diferenças entre os tratamentos estudados, com início próximo a 735 nm. Analisando a curva espectral, observa-se que o tratamento T-2 foi o que, em média, apresentou menor valor de reflectância na região mencionada.

Por outro lado, o tratamento que recebeu maior dose de K (T-12) apresentou a maior amplitude nesta região, decorrente das melhores condições de desenvolvimento em que as plantas foram impostas. A maior amplitude é considerada indicativo de vegetação sadia, devido a interação da REM com as células e paredes celulares hidratadas do mesófilo foliar, promovendo múltiplos espalhamentos internos, resultando no aumento da reflectância nesta região. As plantas dos demais tratamentos embora não mostrasse sintomas visíveis de deficiência, possivelmente, a nível celular, apresentaram mudanças, promovendo as alterações nesta região.

Quando comparado o espectro de reflectância entre o sensor não imageador hiperespectral ASD FieldSpec 3 Jr. e o sensor imageador hiperespectral AisaFENIX nos tratamentos T-6 e T-12, especialmente na região do infravermelho próximo, nota-se que este último sensor, apresentou melhor sensibilidade em diferenciar as curvas espectrais destes tratamentos. Esta característica pode ser explicada pela representatividade da leitura espectral que os mesmos realizam.

O espectrorradiômetro terrestre (ASD FieldSpec) possui, aproximadamente, 4,52 cm² de área útil para leitura com o ASD Plant Probe, realizando-a em uma única folha entre todas as presentes em uma planta (Figura 13). Mesmo com a realização de cinco leituras espectrais de cinco folhas de plantas diferentes, a representatividade ainda é muito baixa, pois podem ocorrer erros nas leituras devido a presença de folhas manchadas ou não representativas da

condição de tratamento imposta, comprometendo a qualidade da curva espectral e, conseqüentemente, os resultados.

Para contornar este problema há necessidade em realizar maior número de leituras nas parcelas experimentais, conseguindo, portanto, maior representatividade e uniformidade na resposta espectral das plantas; porém, em termos operacionais, torna-se extremamente dificultoso devido ao tempo de caminhamento e demora na realização das mesmas.



Figura 13 – Leitura espectral da folha do milho com o ASD Plant Probe.

Já o sensor hiperespectral aerotransportado AisaFENIX, por operar sob o sistema “*Push – broom*” ou seja, escaneamento em linha, com varredura espacial constante durante o sobrevoo, o sistema registra as respostas espectrais e também a imagem correspondente dos alvos de interesse de toda área aeroimageada.

Deste modo, é possível obter o espectro de reflectância de toda a área das parcelas experimentais utilizando de ferramentas computacionais, como exemplo, a Região de Interesse (*Region of Interest - ROI*) do software ENVI conseguindo, portanto, maior representatividade da área estudada e a identificação de diferenças sutis muitas vezes não identificada por outros sensores.

Com isso, embora foi possível a diferenciação da condição extrema de deficiência de K (T-3) através dos IV's, obtidos nas câmeras digitais acopladas ao VANT e o espectrorradiômetro em solo, o que é extremamente satisfatório, a identificação de situações “intermediárias”, como exemplo o tratamento T-6 (“fome oculta”), torna-se muito difícil por meio dos mesmos, devido à menor sensibilidade dos IV's.

Há, portanto, a necessidade de incorporação de técnicas estatísticas mais avançadas buscando a identificação e seleção de faixas ou comprimentos de onda, a partir dos dados de

sensores hiperespectrais, de maior sensibilidade. A simples relação linear entre duas bandas do espectro eletromagnético, ou seja, os IV's, podem ocultar informações cruciais para a identificação de determinadas condições em que as plantas são impostas a se desenvolverem, neste caso, a “fome oculta”, com base no espectro de reflectância.

Deste modo, para explorar o máximo de informações obtidas pelos sistemas hiperespectrais, há necessidade em predeterminar subconjuntos de comprimentos de ondas estreitos, sem que haja perda de informações importantes sobre os alvos em estudo, utilizando de vários métodos estatísticos multivariados. Entre estes, podemos citar como exemplo, os trabalhos utilizando de redes neurais artificiais em milho (*Zea mays* L.) conduzidos por Goel et al., (2003) e em trigo (*Triticum aestivum* L.) por Wang et al., (1999), o método da árvore de decisão em milho para identificação do “status” nutricional do N (GOEL et al., 2003), métodos de análise de dados por componentes principais, análise discriminante de plantas de tomate (*Solanum lycopersicum*), de trigo e de milho, para identificação de plantas daninhas e estresse por deficiência de nitrogênio (GIRMA et al., 2005; KARIMI et al., 2005; SLAUGHTER et al., 2004), identificação espectral de diferentes nutrientes em folhas de girassol (*Helianthus annuus*) (PEÑUELAS et al., 1994), entre outros.

Por fim, devido a possibilidade de diferenciação conseguida pelo sensor AisaFENIX (Figura 12), realizou-se a modelagem de funções discriminantes buscando a discriminação do T-2, do T-6 do T-12, sendo posteriormente avaliado a qualidade dos modelos obtidos.

Antes da realização deste procedimento, a análise por componentes principais (ACP) foi efetuada para a visualização da distribuição dos tratamentos em um plano cartesiano bidimensional, conforme apresentado no próximo tópico.

5.5. Análise de componentes principais (ACP) a partir de dados de reflectância obtido pelo sensor imageador hiperespectral AisaFENIX

A ACP é uma técnica de análise do campo estatístico multivariado resultante da combinação linear de todas as variáveis respostas (comprimentos de onda) de maneira que possa explicar a máxima variância através de suas componentes, não correlacionadas entre si e estimadas com o propósito de reter o máximo de informação de variação total contida nos dados iniciais, promovendo a redução da dimensionalidade dos dados.

Esta redução na dimensionalidade promovida pela componente principal também tem o propósito de permitir o agrupamento de indivíduos similares, mediante exames visuais em dispersões gráficas no espaço bi ou tridimensional de fácil interpretação geométrica.

Na Figura 14 encontra-se os resultados da ACP. Observa-se as contribuições acumuladas dos dois primeiros componentes, sendo que na primeira componente há explicação de 98% da variância dos dados e já para a segunda componente a explicação dos 2% restantes. Tais resultados são satisfatórios, pois de acordo Wang et al., (1999) quando a contribuição cumulativa é elevada já nas primeiras componentes, em termos numéricos de 80 – 85%, há grande possibilidade em separação de indivíduos em grupos, sendo possível aferir tal distribuição em um plano cartesiano bidimensional sem distorções devido a presença de outro eixo.

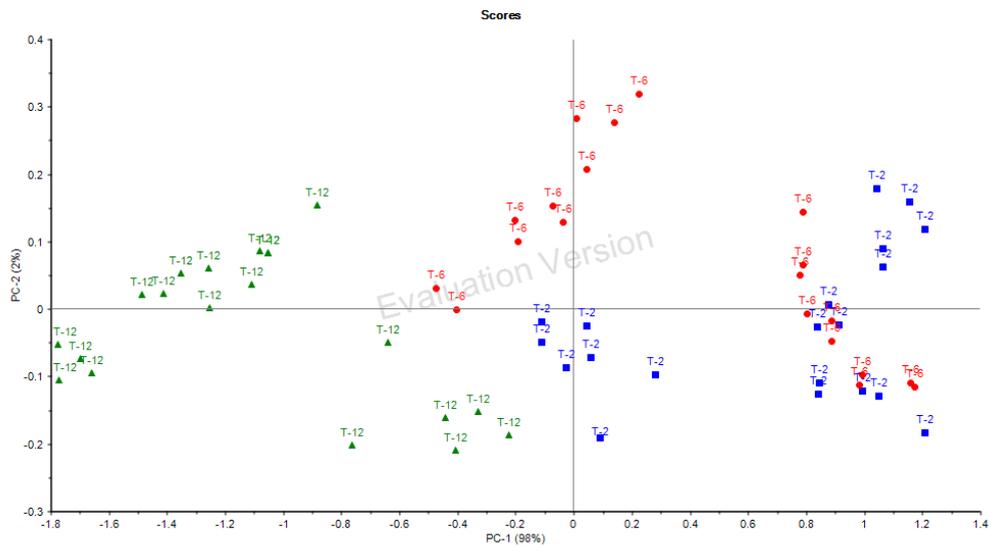


Figura 14 - Dispersão dos scores da primeira e segunda componentes principais referentes aos tratamentos T-2, T-6 e T-12.

Observa-se que o tratamento T-12 não apresentou confundimento com os demais tratamentos, apresentando tendência em formar grupos individuais situados mais à esquerda do gráfico, apresentando scores mais negativos na primeira componente. Essa característica de formação de grupo sem confundimento deve-se a uniformidade do espectro de reflectância, onde quase todas as curvas apresentaram maior amplitude em relação às demais, conforme observado na Figura 14.

Por outro lado, os demais tratamentos apresentaram tendência de formação de grupos localizados mais à direita da primeira componente (CP-1), apresentando valores de scores de -0,5 a 0,3. É possível observar ainda que houve confundimento entre os tratamentos T-2 e T-6, que era de ser esperada devido a maior similaridade entre as curvas espectrais destes tratamentos, porém, ainda assim, é possível a separação de indivíduos.

Deste modo, a partir destes resultados, as curvas espectrais foram submetidas a modelagem para obtenção de funções discriminantes para separação entre os tratamentos.

5.6. Funções discriminantes a partir da curva espectral obtida pelo sensor imageador hiperespectral Aisa FENIX

A função discriminante permite o conhecimento das variáveis que mais se destacam na discriminação dos tratamentos a partir de testes estatísticos para seleção de variáveis como o lambda de Wilk's, a correlação canônica, teste de qui-quadrado, entre outros parâmetros.

Deste modo, das 117 bandas espectrais do sensor AisaFENIX estabelecidas entre os comprimentos de onda de 450 a 1.200 nm apenas 17 foram selecionadas pelo procedimento proc STEPDISC do software SAS ao nível de significância de 10%. Os parâmetros da estatística multivariada utilizada na diferenciação entre os tratamentos estudados são apresentados na Tabela 12.

Tabela 12. Seleção de bandas espectrais para participação na construção dos modelos discriminantes lineares a partir de dados do sensor hiperespectral AisaFENIX.

Passos	Banda Escolhida	Banda Removida	p-valor do teste F	Lambda Wilk's	Correlação Canônica	p-valor da Correlação Canônica
1	776		<,0001	0,453	0,273	<,0001
2	735		0,0002	0,352	0,353	<,0001
3	1063		0,0024	0,294	0,386	<,0001
4	1170		0,0532	0,269	0,420	<,0001
5	1017		0,0049	0,228	0,475	<,0001
6	1142		0,0104	0,198	0,499	<,0001
7		1063	0,4724	0,203	0,492	<,0001
8	1057		0,0285	0,181	0,530	<,0001
9	1023		0,0597	0,166	0,547	<,0001
10	625		0,0913	0,153	0,564	<,0001
11	742		0,0005	0,120	0,623	<,0001
12	549		0,0094	0,102	0,640	<,0001
13	1175		0,0231	0,090	0,655	<,0001
14		1023	0,1294	0,096	0,639	<,0001
15	728		0,0049	0,080	0,665	<,0001
16	646		0,0579	0,073	0,680	<,0001

17	639	0,0459	0,065	0,698	<,0001
18	708	0,0613	0,059	0,719	<,0001
19	1023	0,0961	0,054	0,735	<,0001

Observa-se que o comprimento de onda correspondente ao infravermelho próximo A1063 e A1023 não atingiu o critério de seleção estatisticamente significativa para dar entrada no modelo discriminante.

Conforme observado na Figura 12, as maiores diferenças visuais no espectro de reflectância compreendeu a região do infravermelho próximo, sendo estes comprimentos de onda os que mais atingiram a significância para entrada no modelo pela seleção STEPDISC, sendo selecionados 10 comprimentos de onda desta região.

Observou-se também, que alguns comprimentos de onda da região do vermelho do espectro foram selecionados para participação no modelo. Porém, conforme visualizado nas curvas espectrais dos tratamentos, a amplitude nesta região do espectro não é tão evidente. No entanto, o procedimento utilizado apresentou sensibilidade suficiente em selecionar algumas bandas nesta faixa espectral para compor o modelo. Com relação as demais regiões do espectro de reflectância, apenas uma banda foi selecionada na região verde, sendo esta de altíssima significância, indicando que a mesma apresenta bom peso para participar no modelo discriminante.

Resultados semelhantes foram encontrados por Gomez-Casero et al., (2007), utilizando o mesmo procedimento em dados de reflectância de plantas de oliveira sob 10 anos de deficiência de K avaliando em dois anos consecutivos (2004 e 2005). O método selecionou 26 comprimentos de ondas na região do visível e infravermelho próximo para discriminação das plantas, sendo que no ano de 2004, 75% dos comprimentos de onda compreendiam a região do infravermelho próximo. De maneira análoga ocorreu no ano de 2005, selecionando a maior parte na mesma região mencionada anteriormente.

Ainda analisando a Tabela 12, o teste F mostrou que quase todas as variáveis escolhidas, excluindo as variáveis A1023, A625 e A708, foram altamente significantes, estando muito além do valor estabelecido de 10% de probabilidade de erro.

Com relação ao Lambda de Wilk's, os mesmos apresentaram valores consideravelmente baixos, este parâmetro estatístico pode variar de 0 a 1 e é utilizado para medir a capacidade das variáveis na diferenciação entre grupos (tratamentos). Quando obtidos valores baixos, é um indicativo de que as variáveis apresentam boas propriedades para discriminação dos tratamentos estudados, com base na utilização de dados de reflectância. Os

comprimentos de onda com menor peso observado foram de A776 e A735, apresentando valores de Λ de Wilk's de 0,453 e 0,352 respectivamente. Embora superiores aos demais, este valor é considerado como extremamente satisfatório.

De acordo com os valores do quadrado médio da correlação canônica (ASCC) é possível observar que as bandas A776 e A735 apresentaram menor valor, sendo de 27,3% e 35,3%, enquanto que a maioria das outras bandas espectrais apresentaram valores superiores a 50%, indicando que as variáveis representam bem a variação nos dados na diferenciação entre os tratamentos.

Após a escolha das 17 variáveis que elaborariam o modelo, procedeu-se a realização da análise discriminante por meio do procedimento proc DISCRIM do software SAS.

As equações obtidas para os tratamentos estudados utilizando os dados de reflectância determinados pelo sensor AisaFENIX, são apresentados na Tabela 13.

Tabela 13. Coeficientes dos modelos discriminantes lineares.

Variáveis	Tratamentos		
	T-2	T-6	T-12
Constante	-1217	-1275	-1337
A776	1322	1117	1657
A735	-4202	4600	-9178
A1063	21,82236	59,09420	-12,10009
A1170	-4002	-1446	-6226
A1017	-2143	-2192	-2386
A1142	1373	524,08399	2609
A1057	1591	1747	1659
A1023	-64,51666	-103,36510	-105,40226
A625	4560	4065	5155
A742	22595	19771	27268
A549	-3375	-3163	-3671
A1175	3080	1429	4269
A728	-35225	-42015	-36998
A646	-977,71078	-614,87953	-1174
A639	-2267	-2672	-2390
A708	19717	21005	21551
A1023	-64,51662	-103,36496	-105,40223

Conforme demonstrado no Tópico 4.9.1.1., para obtenção dos modelos discriminantes, o procedimento proc DISCRIM possui um critério de classificação baseado no quadrado da distância generalizada entre os grupos (tratamentos), chamado de distância generalizada de Mahalanobis. Este critério de classificação é baseado em uma matriz de covariância individual dentro do grupo e uma matriz de covariância agrupada.

Deste modo, cada observação é colocada no grupo a partir da qual apresenta 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). O teste de homogeneidade das matrizes de covariância dentro do grupo para os dados espectrais não atingiu o critério de significância ao nível de 10% de probabilidade de erro, sendo, portanto, utilizada na função discriminante. Os resultados deste procedimento são apresentados na Tabela 14, abaixo.

Tabela 14. Quadrado da distância generalizada entre as médias dos tratamentos.

Tratamento	T-12	T-2	T-6
T-12	0	21,269	34,229
T-2	21,269	0	11,500
T-6	34,229	11,500	0

Observa-se que os tratamentos T-2 e T-6, embora similares em termo de deficiência por K, apresentou valor da distância generalizada de Mahalanobis de 11,50, indicando que existe diferenças entre os mesmos em termos espectrais. Com relação ao tratamento padrão (T-12), o mesmo apresentou valor de distância de 21,26 para o tratamento T-2 e 34,22 para o tratamento T-6, indicando que o procedimento apresenta boa probabilidade de separação por dos tratamentos meio deste.

Após obtidas as funções discriminantes, pôde-se determinar a qual destes tratamentos uma determinada curva espectral retirada da mesma área de estudo pertence. Porém, há necessidade em selecionar as bandas espectrais em reflectância nos mesmos valores selecionados pelo procedimento mencionado anteriormente sendo, posteriormente, inseridos nas equações discriminantes obtidas. Como critério de classificação e escolha, a equação que apresentar o maior valor indicará que a leitura desconhecida terá maior probabilidade de fazer parte do tratamento da equação.

Tabela 15. Resumo da resubstituição usando a função discriminante linear.

Tratamentos	T-12	T-2	T-6	Total
T-12	24 100,00	0 0,00	0 0,00	24 100,00
T-2	0 0,00	22 91,67	2 8,33	24 100,00
T-6	0 0,00	2 8,33	22 91,67	24 100,00
Total	24 33,33	24 33,33	24 33,33	72 100,00

Os resultados da Tabela 15 mostram que o tratamento T-12 não foi confundido com nenhum outro tratamento estudado, apresentando 100% de acerto, ou seja, a função discriminante gerada foi capaz de agrupar o tratamento somente com base na resposta espectral das bandas selecionadas pelo procedimento STEPDISC. Coincidentemente, os tratamentos T-6 e T-2 apresentaram 91,67% de acerto, valores estes extremamente elevados, o que indica o alto poder de discriminação. Em ambos os tratamentos houve a classificação de 22 amostras entre as 24 curvas espectrais coletadas da imagem hiperespectral obtida pelo sensor AisaFENIX, classificando apenas 2 leituras de forma errada.

Na Tabela 16 é mostrado o erro de classificação dos tratamentos, observa-se que os tratamentos T-2 e T-6 apresentam erro de classificação de 8,33% para ambos casos, resultados estes extremamente baixos. O erro global médio na classificação foi de 5,56%, confirmando a precisão da classificação e o alto poder discriminatório do modelo obtido.

Tabela 16. Estimativa do erro para cada tratamento reclassificado pela análise discriminante.

Tratamentos	T-12	T-2	T-6	Total
Taxa	0,000	0,083	0,083	0,056
P	0,333	0,333	0,333	1

Objetivando melhorar e testar a qualidade dos modelos obtidos, foi realizada a simulação no software SAS onde 60% das curvas espectrais obtidas aleatoriamente entre as parcelas experimentais foram utilizadas na construção de um novo modelo discriminante para cada tratamento estudado, sendo posteriormente testado pelos 40% restante das curvas espectrais. A escolha dos componentes que fariam parte da análise discriminante foi aleatória,

ou seja, o próprio sistema determinou quais as curvas espectrais entrariam na simulação. Este processo de simulação foi repetido por 50 vezes, ou seja, o sistema escolheu aleatoriamente 60% das curvas espectrais para geração dos modelos discriminantes e 40% para teste (CEZAR et al., 2013).

Ao final da simulação os resultados da Tabela 17 mostra a frequência e a porcentagem de classificação das curvas espectrais dentro do modelo de cada tratamento em questão. Nesta etapa, as próprias curvas espectrais que foram utilizadas na geração do modelo foram reclassificados pelo mesmo.

Tabela 17. Resultados obtidos por meio da análise discriminante simulada com dados usados no modelo (60%).

Tratamentos	T-12	T-2	T-6	Total
T-12	768	0	0	768
	34,75	0,00	0,00	34,75
Observado →	100,00	0,00	0,00	
Estimado →	100,00	0,00	0,00	
T-2	0	712	21	733
	0,00	32,22	0,95	33,17
Observado →	0,00	97,14	2,86	
Estimado →	0,00	95,70	3,01	
T-6	0	32	677	709
	0,00	1,45	30,63	32,08
Observado →	0,00	4,51	95,49	
Estimado →	0,00	4,30	96,99	
Total	768	744	698	2210
	34,75	33,67	31,58	100,00

Observa-se que de maneira análoga a análise discriminante com todas as curvas, o tratamento T-12 não foi confundido com nenhum outro tratamento, tendo sido encontrado por 768 vezes durante o processo com acerto de 100% para as frequências observadas e estimadas. Tal condição era esperada devido à uniformidade das plantas no campo experimental e a condição ótima de adubação que a mesma foi submetida, fatores estes que contribuíram para a uniformidade da curva espectral e consequentemente na construção de um modelo confiável.

Constatou-se, também, que o tratamento T-2 foi o segundo melhor classificado pelo modelo gerado, apresentando 97,14% de acerto para as frequências observadas, com classificação certa de 712 vezes e confundimento de apenas 21 vezes com o tratamento T-6.

Já para o tratamento T-6, o mesmo apresentou a menor porcentagem de acerto, porém, valor extremamente elevado, sendo de 95,49%. Houve maior confundimento para este tratamento em relação aos demais, apresentando classificação certa de 677 vezes e errada de 32 vezes, sendo nestas vezes classificado erroneamente como o tratamento T-2.

O teste Qui-quadrado para a tabela de frequência, mostrou que na simulação as frequências observadas e estimadas foram significantes estatisticamente ($P < 0,0001$). Este parâmetro estatístico é utilizado para avaliar, quantitativamente, a relação entre o resultado observado e o resultado estimado por meio de simulações, indicando o quanto os valores podem ser aceitos estatisticamente.

Das 50 simulações realizadas, as observações participaram dos modelos discriminantes em uma frequência total de 2210 tentativas, sendo que destas, 53 vezes os modelos classificaram de forma errada, representando cerca de 2,39%. Por outro lado, os modelos acertaram 2157 vezes os tratamentos a que pertenciam as curvas espectrais, sendo uma frequência de aproximadamente 97,60%. O coeficiente de contingência, utilizado para medir o grau de associação entre duas classes, mostrou que os modelos discriminantes apresentaram $r = 0,8063$.

Após a realização do procedimento de construção do modelo discriminante com 60% das curvas espectrais dos tratamentos, a etapa seguinte foi em avaliar o desempenho do modelo construído com o restante das curvas espectrais, ou seja, os 40% de amostras restantes, as quais não participaram da geração do mesmo. Os resultados de erros a certos são apresentados na Tabela 18.

Tabela 18. Resultados obtidos por meio da análise discriminante simulada com dados usados no modelo (40%).

Tratamentos	T-12	T-2	T-6	Total
T-12	387	35	10	621
	27,84	2,52	0,72	33,51
Observado →	89,58	8,10	2,31	
Estimado →	89,58	7,76	1,97	
T-2	44	344	79	467
	3,17	24,75	5,68	33,60
Observado →	9,42	73,66	16,92	
Estimado →	10,19	76,27	15,58	
T-6	1	72	418	491
	0,07	5,18	30,07	35,32
Observado →	0,20	14,66	85,13	
Estimado →	0,23	15,96	82,45	
Total	432	451	507	1390
	31,08	32,45	36,47	100,00

Observa-se que o tratamento com maior teor de K^+ (T-12) foi o que apresentou maior porcentagem de acerto, tanto para os valores observados, quanto para os valores estimados, ambos com 89,58% de acerto. Já para o tratamento T-2, observou-se a menor porcentagem de acerto em relação aos demais tratamentos, sendo de 73,66% para os valores observados e de 76,27% para os valores estimados.

Com relação ao tratamento T-6, denominado de “fome oculta”, o mesmo apresentou porcentagem de acerto, para os valores estimados, de 82,45% e 85,13% para os valores observados. Sendo assim, como observado para o tratamento T-12, os maiores acertos nesta análise discriminante.

De maneira semelhante aos modelos gerados com 60% das curvas espectrais, os resultados obtidos com os 40% restante das amostras, mostrou-se ser significativo pelo teste de Qui-quadrado ($p < 0,0001$), embora as frequências observadas e estimadas para cada tratamento estudado tenham sido menores em relação ao modelo anterior. Mesmo com esta redução, o coeficiente de contingência apresentou valor de $r = 0,7287$, entre os observados e estimados, sendo considerado excelente resultado.

Analisando as classificações consideradas como erradas do modelo discriminante gerado (Tabela 18), observou-se que o tratamento T-12 foi encontrado no processo por 387

vezes, sendo classificado de maneira errada em 35 vezes como o tratamento T-2 e 10 vezes como tratamento T-6. Com relação ao tratamento T-2, o mesmo foi encontrado por 344 vezes e classificado 44 vezes como sendo o tratamento T-12 e 79 vezes como o tratamento T-6. Já para o tratamento T-6, o mesmo foi encontrado por 418 vezes com classificação de 72 vezes como sendo o tratamento T-6 e 1 vez como o tratamento T-12.

Este maior confundimento entre o tratamento T-2 e T-6 deve-se a maior variação observada entre as curvas espectrais destes tratamentos, possivelmente, devido ao efeito da deficiência nutricional no crescimento das plantas e conseqüentemente ocasionando heterogeneidade no espectro de reflectância, sendo muitas vezes sobrepostas e levando o modelo discriminante classificar uma resposta espectral de um tratamento como sendo de outro. Porém, observou-se que os modelos apresentaram elevada porcentagem de acerto o que pode-se concluir, que esta análise discriminante é válida e sensível na diferenciação.

Gomez-Casero et al., (2007), obtiveram o melhor resultado de classificação com precisão global de cerca de 95% para plantas de oliveira com deficiência de K e 94% quando supridas por este elemento, concluindo que é possível discriminá-las sob esta condição utilizando-se dados espectrais.

Com os resultados obtidos é possível extrapolar os modelos discriminantes para a identificação da condição de fertilidade de K em milho em outras áreas agrícolas através da inserção das equações em softwares computacionais, obtendo mapas de anomalia deste elemento de maneira rápida e precisa, contribuindo para o rápido manejo da adubação evitando perdas na produtividade.

5.7. Modelos de regressões lineares para predição do teor potássio foliar utilizando os índices de vegetação obtidos por câmeras digitais acopladas ao VANT

Objetivando estudar a relação do IV's significantes obtidos pelas câmeras digitais acopladas ao VANT com a concentração foliar de K no milho, procedeu-se a modelagem em regressões lineares avaliando a qualidade preditiva para este elemento com base na utilização dos IV's como variável independente no modelo obtido. Para evitar possíveis problemas de multicolinearidade nos modelos de regressões, os mesmos foram construídos com base na utilização de apenas um IV por vez, sendo estes o RVI, RNIR, NDVI, GNDVI, GRVI e GNIR. Este procedimento foi realizado para os estádios de desenvolvimento V7, V12 e R3.

Observa-se na Tabela 19, que no estádio de desenvolvimento V12 apenas o IV RVI apresentou não significância para o coeficiente da regressão β_0 , mesmo que o teste F para o modelo foi atendido ao nível de 5% probabilidade de erro fixado na análise, o coeficiente β_0 passou pela origem o que invalida o modelo. Similarmente para R3 os IV's GNDVI, GRVI e GNIR não foram estatisticamente significantes para o teste F do modelo de regressão linear e também para o teste "t" dos coeficientes do modelo obtido.

Nota-se que em V7 o modelo de regressão linear utilizando o IV RVI apresentou valor alto de coeficiente de correlação de Pearson (r), sendo de 0,84, indicando que o mesmo apresenta boa relação com o K. Todos os coeficientes da regressão foram significantes estatisticamente. O coeficiente de determinação da regressão (R^2) foi de 0,71, valor este considerado como satisfatório, pois este parâmetro aponta o quanto o ajuste de uma regressão linear generalizada consegue explicar os valores observados. Neste caso, o modelo obtido consegue explicar 71% da variabilidade do K foliar.

Resultados similares podem ser observados para V12 para os IV's GRVI e RVI e em R3 para os IV's NDVI e RNIR, sendo todos com valores de "r" superior a 0,80, indicando que tais índices apresentam boa relação com o K e, portanto, factível de ser utilizado para estimar tal elemento em estudo.

Com relação aos IV's GNDVI e GNIR no estádio V12, pôde-se considerar que os mesmos apresentaram boas propriedades estatísticas, ou seja, atingiram significância para o teste F e os coeficientes da regressão β_0 e β_1 , porém não apresentam boa capacidade para estimar precisamente o K foliar, quando o objetivo pretendido seja a substituição do método laboratorial de análise deste elemento, pois a correlação de Pearson foi de 0,69 para o GNDVI e -0,73 para o GNIR, e conseqüentemente o coeficiente de determinação baixo, uma vez que $r = \sqrt{R^2}$. Contudo, ainda assim, é aceitável a utilização de tais modelos para o conhecimento do

“status” nutricional da lavoura, uma vez que é possível a identificação de zonas de anomalias pela deficiência de K através da utilização de câmeras digitais de baixo custo acopladas à VANT’s.

Tabela 19. Modelos de regressões lineares para estimativa de K foliar utilizando os IV’s obtidos por câmeras digitais acopladas ao VANT.

Estádio de desenvolvimento	Índice de vegetação	<i>r</i> (Pearson)	<i>R</i> ²	Concentração de K foliar (<i>g kg</i> ⁻¹)
V7	RVI *	0.84	0.71	$\hat{y} = -41.41001 + 3.41337 \times \text{RVI}$
	GNDVI *	0.69	0.48	$\hat{y} = -182.15544 + 224.49065 \times \text{GNDVI}$
V12	GRVI *	0.89	0.79	$\hat{y} = -13.67395 + 1.79160 \times \text{GRVI}$
	GNIR *	-0.73	0.54	$\hat{y} = 44.21174 - 459.14461 \times \text{GNIR}$
	RVI *	0.84	0.71	$\hat{y} = -10.29291 + 1.36658 \times \text{RVI}$
R3	NDVI *	0.83	0.69	$\hat{y} = -399.72247 + 473.94826 \times \text{NDVI}$
	GNDVI *	0.55	0.31	$\hat{y} = -232.02492 + 289.11171 \times \text{GNDVI}$
	RNIR *	-0.84	0.71	$\hat{y} = 73.79324 - 869.47219 \times \text{RNIR}$
	RVI ^{ns}	0.62	0.39	$\hat{y} = -32.35337 + 3.20946 \times \text{RVI}$
	GRVI ^{ns}	0.47	0.22	$\hat{y} = -17.69760 + 2.50443 \times \text{GRVI}$
	GNIR *	-0.62	0.39	$\hat{y} = 59.90354 - 555.16151 \times \text{GNIR}$

*Significante ao nível α de 5% de probabilidade de erro ($p\text{-valor} \leq 0.05$), ^{ns} Não-significante ($p\text{-valor} > 0.05$).

Modelos de regressões lineares têm sido amplamente utilizados para a estimativa de teores de nutrientes nas plantas como, por exemplo, o N foliar, apresentando grande performance e resultados consistentes. Entre os trabalhos podemos citar os conduzidos por OSBOURNE et al., (2007), TIAN et al., (2011), PEÑUELAS et al., (1994), entre outros.

Porém, quando aplicado para outros elementos, observa-se que os resultados não apresentam um padrão uniforme.

Entre os poucos trabalhos que buscaram a estimação do K com base na utilização de apenas os IV’s encontram-se o realizado por Guo et al., (2017) na cultura da maçã. Os autores encontraram valor de coeficiente de correlação entre os IV’s RVI e NDVI e o conteúdo de K foliar de aproximadamente 0,40, indicando que o K não se relaciona bem com os IV’s.

Porém, neste mesmo trabalho, os autores utilizaram de outra técnica estatística para a modelagem da regressão denominada de *Random Forest*, que trata-se de uma ferramenta de modelagem não linear baseada na técnica da árvore de decisão. Aplicando este método, os mesmos obtiveram coeficiente de determinação superiores a 0,85 para ambos os IV’s

estudados, demonstrando que embora pareça não haver boa relação entre as variáveis em estudo a utilização de diferentes técnicas estatísticas pode melhorar a compreensão dos resultados.

Mahajan et al., (2014) utilizando de IV's para monitorar nutrientes em plantas de trigo obtiveram valor de coeficiente de correlação para NDVI e GNDVI com nitrogênio e K de 0,30 e 0,29, respectivamente, sendo valores considerados extremamente baixos, embora significantes pelo teste "t".

Coomer-Taylor (2016) trabalhando com a cultura do algodão submetido à deficiência de K obteve valor de correlação de Pearson de 0,81 para o IV NDVI quando relacionado com a concentração de K foliar.

Navarro (2012) avaliou a relação do NDVI com K foliar em plantas de soja em diferentes estádios de desenvolvimento, o autor concluiu que houve uma correlação positiva entre NDVI e K nos estádios iniciais. Quando as plantas estavam no início do estágio reprodutivo o NDVI foi mais sensível à deficiência de K, exibindo maior valor de R^2 nas regressões, sendo superior a 0,80.

Na Tabela 20 encontra-se os resultados da estimativa do K foliar por meio dos IV's obtidos pelas câmeras digitais acopladas ao VANT *versus* os dados da análise de laboratório utilizado como referência. Somente as regressões lineares que apresentaram valor do coeficiente de correlação de Pearson superior a 0,80 foram submetidas ao processo de predição deste elemento.

Tabela 20. Estimativa do K foliar em g kg^{-1} por meio dos IV's obtidos por câmeras digitais acopladas ao VANT nos estádios de desenvolvimento V7, V12 e R3.

Referencia	V7	Referencia	V12	RVI	R3	
	RVI		GRVI		Referencia	Referencia
	Estimado ¹		Estimado ¹		Estimado ¹	
5.26	-1.08 ^{ns}	5.08	8.71 [*]	5.85 [*]	3.60	5.26
6.06	2.07 ^{ns}	7.00	11.72 [*]	8.10 [*]	3.78	6.06
6.64	14.04 ^{ns}	9.61	9.00 [*]	7.12 [*]	4.11	6.64
7.32	4.53 ^{ns}	11.30	12.60 [*]	11.91 [*]	5.29	7.32
18.40	28.39 [*]	12.45	14.94 [*]	16.62 [*]	13.00	18.40
20.28	27.92 [*]	13.16	20.98 [*]	19.23 [*]	13.77	20.28
24.51	28.51 [*]	14.69	19.08 [*]	18.20 [*]	15.55	24.51
24.66	27.69 [*]	14.94	14.63 [*]	17.47 [*]	16.72	24.66
28.59	29.83 [*]	16.44	14.53 [*]	17.37 [*]	17.24	28.59
28.74	32.33 [*]	16.45	16.52 [*]	17.70 [*]	17.31	28.74
29.30	29.75 [*]	17.85	15.32 [*]	17.66 [*]	20.63	29.30
30.56	25.82 [*]	19.10	16.90 [*]	18.23 [*]	21.14	30.56
35.76	27.64 [*]	24.37	16.76 [*]	18.49 [*]	29.26	35.76
37.64	30.47 [*]	25.17	14.51 [*]	17.35 [*]	29.78	37.64
40.38	30.74 [*]	26.51	26.36 [*]	19.22 [*]	30.88	40.38
42.63	32.30 [*]	27.22	30.86 [*]	18.60 [*]	31.51	42.63

¹ Critério de significância: Limites superior e inferior (95%). ^{*} Significante ao nível α de 5% de probabilidade de erro ($p\text{-valor} \leq 0.05$), ^{ns} Não-significante ($p\text{-valor} > 0.05$).

Observa-se em V7 que, durante a estimativa do K foliar, houve amostras que não apresentaram significância em relação às de referência obtida em laboratório, principalmente, as amostras com valor de K muito baixo. De maneira análoga, esta característica pode ser observada no estádio R3 para os IV's NDVI e RNIR apresentando, em alguns casos, valores negativos do elemento.

Por outro lado, em V12, o IV GRVI apresentou significância para todas as amostras estimadas pelo modelo. Nota-se que quando o K foliar foi extremamente baixo (T-3), as amostras foram estimadas com valores próximos a da referência, com valores de K de 5,08 (referência) – 8,71 (estimado), 9,61 – 9,00, em g kg^{-1} .

Com relação a amostras com valores intermediários do elemento, nota-se que no estádio R3, ambos IV's apresentaram superestimação do K em relação os valores de referência. De maneira análoga este comportamento foi observado nas demais datas de

avaliações, porém, apresentando menor tendência de superestimá-lo, produzindo resultados muito próximos a análise laboratorial.

Já, quando os valores de K foram alto, apenas o IV GRVI em V12 apresentou valor estimado relativamente próximo ao de referência, sendo de 26,51 – 26,36 e 27,22 – 30,86 g kg⁻¹. Nos demais estádios avaliados os IV's não demonstraram boa capacidade de estimação, apresentando subestimação do K nestas amostras.

Para contornar os pontos limitantes do processo e melhorar a capacidade de predição dos modelos, pode-se estabelecer novos IV's utilizando de outras bandas do espectro eletromagnético através da aplicação de filtros que permitem a passagem dos comprimentos de onda ou bandas espectrais de maior sensibilidade às condições específicas de desenvolvimento das plantas. Também, torna-se interessante, avaliar a contribuição da incorporação da amplitude entre os espectros de reflectância nos modelos de regressão para estimar tal nutriente.

Contudo, observa-se que os IV's testados apresentaram boa capacidade de estimar o K foliar, exibindo, muitas vezes, valores próximos a análise laboratorial padrão para determinação deste elemento. Tais resultados demonstram que câmeras fotográficas digitais de baixo custo acopladas à VANT, podem tornar-se numa ferramenta extremamente útil para o monitoramento do “status” nutricional do K foliar da cultura do milho, desde que passam por processos de calibrações e utilização de filtro adequados para a restrição de determinadas bandas do espectro eletromagnético, permitindo, portanto, a obtenção de informações que realmente expressam a condição de desenvolvimento da cultura.

5.8. Modelo de predição para produtividade utilizando a regressão por quadrados mínimos parciais (PLSR) a partir dos dados do sensor imageador hiperespectral AisaFENIX

Observa-se na Figura 15 o resultado do teste de “Leverage” e os “Scores” para a identificação de possíveis “Outliers”.

Os “Scores” não indicaram a presença de amostras heterogêneas no conjunto de dados, sendo o limite para ser considerado como “Outliers” a elipse de T^2 Hotelling's, ao nível de 5% de probabilidade de erro.

Já para o Leverage, o mesmo indicou a possível presença de um “Outlier”, porém, esta amostra apresentou valor muito próximo a linha considera como corte para a amostra ser considerada homogênea ou não. Deste modo, a amostra não foi retirada no processo de construção do modelo PLSR, pois foi observado que não houve influência na qualidade de ajuste, ou seja, parâmetros como RMSEC, RMSECV, R^2 e Bias, não apresentaram diferenças significantes quando analisado o modelo sem a mesma.

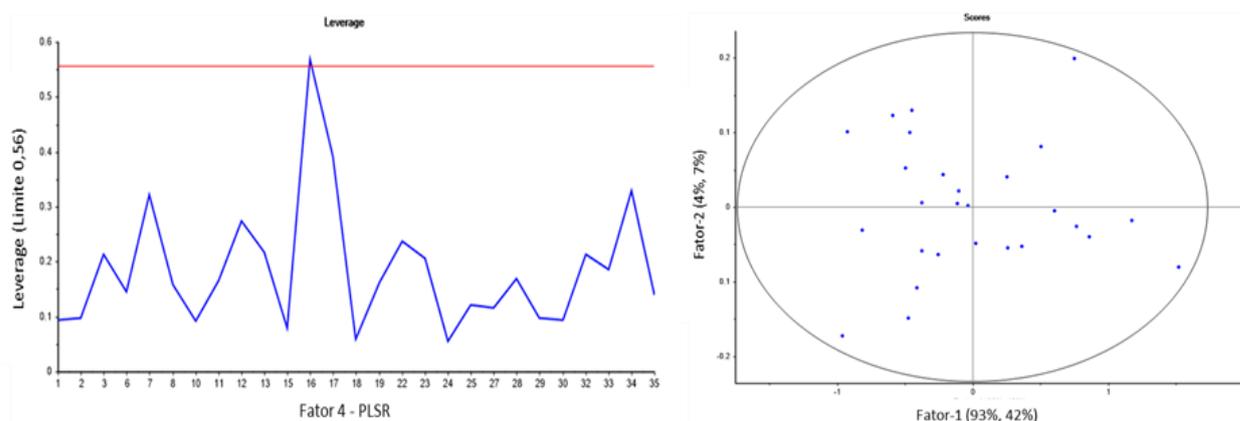


Figura 15 - Resultado do “Leverage” para identificação de possíveis “Outliers” e dispersão das amostras e limite (elipse) de T^2 Hotelling's para identificação de possíveis “Outliers”.

Na primeira fase da obtenção do modelo PLSR para predição da produtividade utilizando o método de validação cruzada, obteve-se que o melhor número de fatores necessários para explicar a maior parte da variação entre as variáveis de estudo, foi com 4 fatores conforme pode ser visualizado na Figura 16.

Observa-se que a partir do fator 4 o erro na validação cruzada (RMSECV) começa a subir à medida que novos fatores são inseridos na construção do modelo, sendo o RMSECV máximo quando 9 fatores são inseridos. Embora é possível visualizar no fator 1 e 2 tendência de pequeno aumento no RMSECV, o mesmo é extremamente pequeno, dando a falsa intenção

de seleção de apenas o fator 1 para construção do modelo. Porém, observa-se a que a partir do fator 2 a queda no RMSEC foi elevada, indicando que novos fatores devem ser inseridos.

Como a ideia central é a permanência do número de fatores que apresenta o menor erro neste processo, ou seja, onde não existe variação apreciável no valor de RMSECV, utilizou-se de 4 fatores para construção e posterior validação dos modelos.

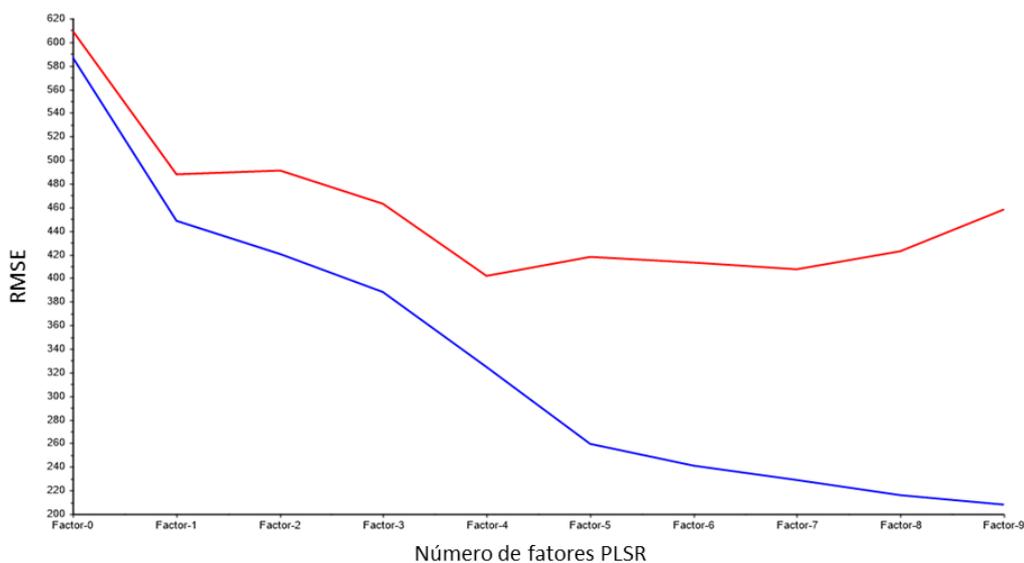


Figura 16 - RMSE da validação cruzada (linha vermelha) e da calibração (linha azul) para escolha do número de fatores ideais para construção do modelo PLSR.

Os parâmetros da qualidade modelo obtido contendo os 4 fatores selecionado no passo anterior é apresentado na Tabela 21.

Observa-se que no modelo de calibração contendo todas as 27 amostras, apresentou R^2 de 0,69, indicando que o modelo possui boa capacidade de predição, porém, o mesmo ainda não foi “testado” pelo método da calibração cruzada, necessitando a estimação dos parâmetros da qualidade do modelo (R^2 , Bias, RMSECV) quando retirada amostras do conjunto de dados para mensurar a capacidade em estimar esta amostra faltante.

Quando realizada a calibração cruzada, o modelo apresentou boa capacidade de predição da amostra retirada neste processo, exibindo valor de R^2 de 0,56, considerado satisfatório, de acordo com Minasny e Mcbratney (2013). Observa-se ainda que o modelo apresentou Bias de 12,83. Como este parâmetro mede a tendência do modelo em superestimar ou subestimar o valor estimado em relação ao observado, onde o valor zero demonstra a perfeição, este resultado mostra que o mesmo apresenta baixíssima tendência de superestimar da produtividade.

Já para o valor do erro na calibração cruzada (RMSECV), o mesmo apresentou pequeno aumento, sendo de 402,24, enquanto na construção do modelo com todas as amostras o valor observado foi de 324,73. Este aumento no erro é esperado durante o processo de estimação da amostra faltante. No entanto, é desejado que não ocorra variações expressivas no mesmo, onde valores elevados é indicativo de modelo com fraca capacidade preditiva.

Quando plotado a linha de tendência entre a calibração e a validação cruzada (Figura 17), observa-se que houve pequeno deslocamento entre as mesmas, indicando que o modelo não “se perdeu” durante a estimação da amostra que foi retirada. Fato este confirmado quando analisados os parâmetros R^2 , RMSEC, RMSECV e Bias (Tabela 21).

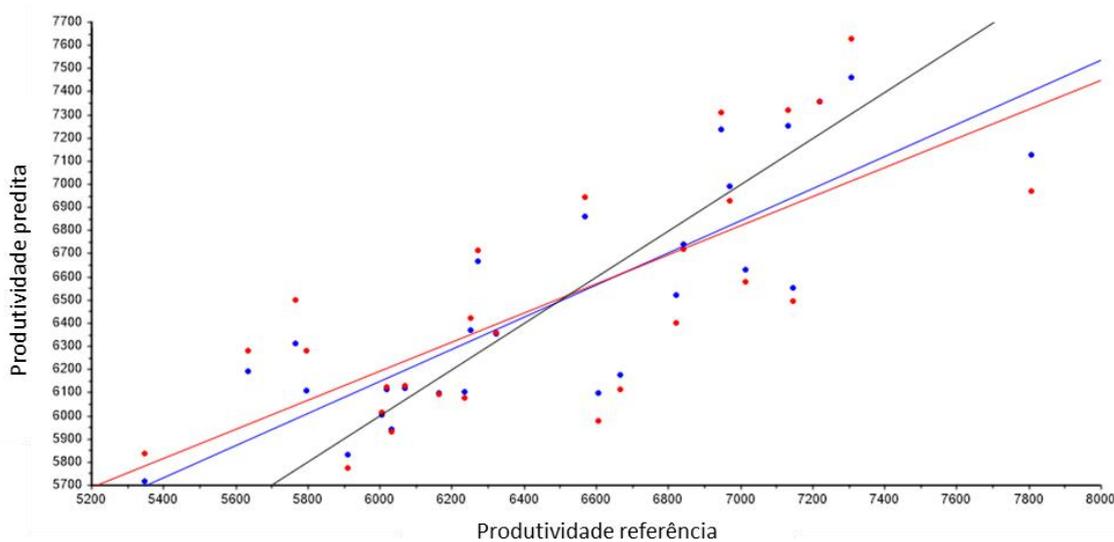


Figura 17 - Dispersão da calibração (linha azul) e calibração cruzada (linha vermelha) versus os dados de referência da produtividade. A linha preta representa a reta 1:1.

Após a análise da calibração cruzada e verificando-se que o modelo apresentou características satisfatória na previsão da produtividade, procedeu-se a aplicação de novas amostras (9) que não participaram na etapa anterior.

Observa-se na Tabela 21 que o modelo manteve-se com boa qualidade de predição, apresentando valor de R^2 de 0,49, enquanto que na validação cruzada, o valor observado foi de 0,56, ou seja, mesmo com a entrada de amostras desconhecidas o modelo foi capaz de estimar satisfatoriamente. Com relação ao erro na predição (RMSEP), o mesmo apresentou pequeno aumento, sendo de 418,62, porém muito próximo com o erro da calibração cruzada. Com relação ao valor de Bias, observou-se leve aumento indicando que o modelo pode apresentar tendência de superestimar da produtividade, porém, com elevada semelhança com o valor de referência.

Willmott (1982), relata que modelos PLSR considerados “bons”, o erro sistemático (Bias) deve aproximar-se de zero, enquanto o erro não-sistemático (SEP) deve se aproximar do valor de RMSEP. Portanto, conclui-se que a performance do modelo PLSR foi boa.

Tabela 21. Parâmetros estatísticos do modelo PLSR para estimação da produtividade em milho.

PLSR	r	R ²	RMSE	BIAS	SEP
Calibração	0,83	0,69	324,73 ^c	0	330,91 ^c
Validação interna	0,74	0,56	402,24 ^{cv}	12,83	409,69 ^{cv}
Validação externa	0,73	0,50	418,62 ^p	67,06	438,28 ^p

^c Valor obtido na fase de calibração do modelo PLSR, ^{cv} Valor obtido na fase de calibração cruzada e ^p valor obtido na fase de predição a partir de novas amostras.

Como o conceito teórico da regressão por quadrados mínimos parciais (PLSR) é que todos os comprimentos de onda apresentam contribuição na construção do modelo em diferentes proporções ou pesos, para predição da variável de interesse, em um gráfico bidimensional é possível a visualização da contribuição de cada comprimento de onda do sensor AisaFENIX, sendo possível ser obtido os coeficientes da regressão PLSR, conforme observado na Figura 18.

Observa-se que na região do vermelho do espectro eletromagnético apresentou maiores valores do coeficiente da regressão, sendo maiores nos comprimentos de onda próximos de 659 e 666 nm, indicando que esta região do espectro apresenta boas características para predição da produtividade. Já a região do infravermelho próximo apresentou diferentes porções de relevância, onde o maior valor foi observado nos comprimentos de onda próximos a 1.186 nm. Em outras faixas espectrais situadas próximos a 838 e 1.073 nm também apresentaram importância para estimação da variável em estudo. As faixas espectrais de menor importância no modelo PLSR foi observado próximo de 748, 989 e 1.017 nm.

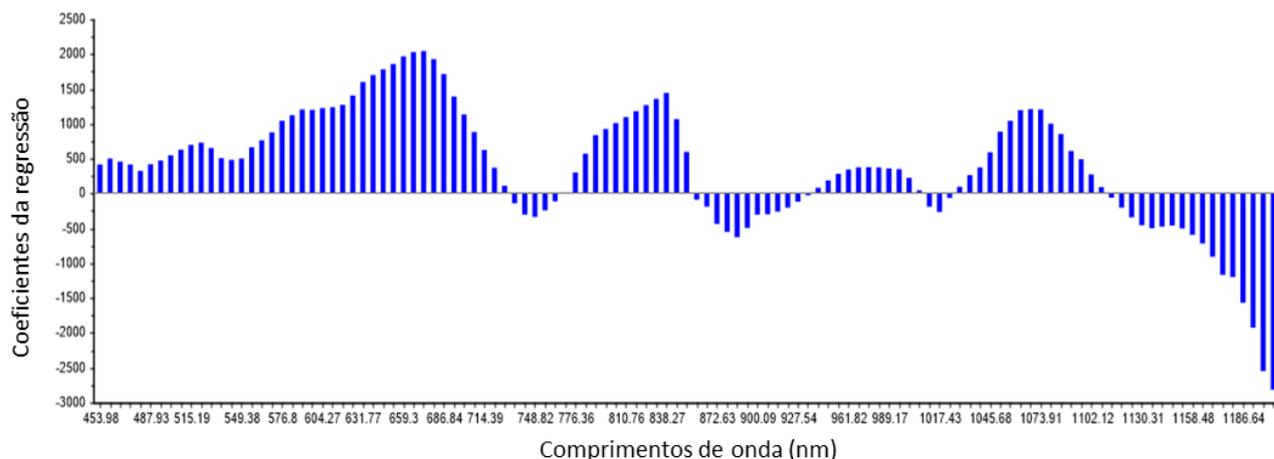


Figura 18 - Coeficientes de regressão do modelo PLSR para predição da produtividade do milho.

Os valores preditos para produtividade a partir do modelo PLSR gerado encontram-se na Tabela 22. Observa-se que o modelo apresentou excelente capacidade de estimação da produtividade quando comparado com os valores de referência, sendo o tratamento T-10 o que mais aproximou-se com os valores de referência. Já as maiores diferenças entre os valores estimados e de referência foram observados para o tratamento T-5 e T-11 apresentando variação de aproximadamente 660 kg ha⁻¹. Porém vale lembrar, que estamos estimando uma variável de alta complexidade utilizando apenas do espectro de reflectância das plantas nos estádios iniciais de desenvolvimento, mesmo com possíveis interferências, ainda assim é possível a estimativa de modo confiável.

Tabela 22. Valores de referência da produtividade e os valores estimados pelo modelo PLS (em kg ha⁻¹).

Tratamentos	Estimado (a)	Referência (b)	Diferença (b – a)
T-2 - Bloco 4	5934,79	5693,40	-241,39
T-5 - Bloco 1	6773,55	6096,70	-676,85
T-6 - Bloco 1	6424,01	6168,70	-255,31
T-7 - Bloco 2	6333,46	6443,60	110,14
T-8 - Bloco 4	6669,69	7169,50	499,81
T-9 - Bloco 1	6892,06	6401,20	-490,86
T-10 - Bloco 2	6440,37	6434,50	-5,87
T-11 - Bloco 3	6458,13	7127,20	669,07
T-12 - Bloco 4	7902,16	7689,80	-212,36

Modelos de predição multivariados são muitos utilizados em outras áreas de pesquisa para estimativa de diversas variáveis a partir da utilização de uma matriz de dados multivariados, porém, estes métodos ainda não são frequentemente aplicados no sensoriamento remoto na agricultura, apresentando elevado potencial em contribuir para o desenvolvimento de modelos robustos de previsão de parâmetros agrícolas de difícil mensuração por outros meios.

Hansen et al., (2002) trabalhando com modelos PLSR para estimar o rendimento em trigo e cevada obtiveram valor de correlação entre o mensurado e predito de 0,96, indicando excelente capacidade na predição do rendimento.

Salazar et al., (2008) utilizaram dados de reflectância do satélite AVHRR de uma série temporal de 23 anos (1982 – 2004) confrontando com dados oficiais de produtividade em milho no estado de Kansas – USA por meio de modelo PLSR. Os autores concluíram que o erro de predição da produtividade do milho foi inferior a 6%, apresentando excelente potencial de aplicação, podendo ser predita de dois a três meses antes da colheita ter sido concluída.

Yang et al., (2004) utilizaram um sensor hiperespectral aerotransportado com 128 bandas espectrais para avaliar o potencial no monitoramento da produtividade em sorgo confrontando com dados obtido por um monitor de produtividade acoplado na colhedora. A análise de correlação mostrou que todas as bandas espectrais foram estatisticamente bem relacionadas com a produtividade. O menor R^2 obtido pelos modelos de regressão, pelo procedimento STEPWISE, foi de 0,57. Neste mesmo trabalho, os autores utilizaram a seleção das bandas espectrais mais significantes para compor o modelo, utilizando da análise de componentes principais para eliminar a redundância nos dados hiperespectrais. Porém, não identificaram diretamente as contribuições de bandas individuais para o mapeamento da produtividade, necessitando da utilização de técnicas estatísticas mais avançadas como os modelos PLSR. Os resultados obtidos demonstram que dados de imagem hiperespectral podem ser uma fonte útil para a estimativa de produção das culturas.

Ye et al., (2007) aplicaram diversos procedimentos estatísticos para estimativa da produtividade em citrus a partir de dados de reflectância obtidos por um sensor hiperespectral aerotransportado, os autores concluíram que a maior precisão de predição foi obtida com o modelo baseado em fatores PLSR do que com os modelos com base na seleção de comprimentos de onda importantes, obtendo valor de R^2 durante a etapa de calibração do modelo de 0,83.

5.9. Modelo de predição do teor potássio foliar utilizando a regressão por quadrados mínimos parciais (PLSR) a partir dos dados do sensor imageador hiperespectral AisaFENIX

Antes da obtenção do modelo de predição, foi realizada a análise de resíduos para possível remoção de amostras anômalas (“outliers”), sendo verificado através dos testes de Leverage e T^2 Hotelling's. De maneira análoga ao modelo obtido para a produtividade, não foi necessário a remoção de amostras visto que a análise de resíduo não indicou presença de “Outliers”. Após isso, foi realizado o método da validação cruzada para encontrar o melhor número de fatores que irá compor o modelo PLSR.

O número de fatores necessários para explicar a maior parte da variação entre as variáveis de estudo foi com 4 fatores, apresentando menor valor de RMSECV. Os parâmetros da qualidade modelo obtido selecionado é apresentado na Tabela 23.

Observa-se que no modelo de calibração contendo todas as 27 amostras, sem a realização da validação cruzada (ou também chamada de validação interna), apresentou R^2 de 0,58, indicando que o modelo possui boa capacidade de predição, porém, o mesmo ainda não foi “testado” pelo método da calibração cruzada, necessitando a estimação dos parâmetros da qualidade do modelo (R^2 , Bias, RMSECV) quando retirada amostras do conjunto de dados para mensurar a capacidade em estimar esta amostra faltante.

Tabela 23. Parâmetros estatísticos do modelo PLSR para estimativa do teor de K foliar em milho.

PLSR	r	R^2	RMSE	BIAS	SEP
Calibração	0,77	0,58	4,32 ^c	0	4,40 ^c
Validação interna	0,61	0,43	5,44 ^{cv}	0,07	5,54 ^{cv}
Validação externa	0,76	0,57	5,27 ^p	-0,47	5,57 ^p

^c Valor obtido na fase de calibração do modelo PLSR, ^{cv} Valor obtido na fase de calibração cruzada e ^p valor obtido na fase de predição a partir de novas amostras.

A calibração cruzada do modelo de predição apresentou valor de R^2 de 0,43, enquanto que na fase de calibração o valor de R^2 foi de 0,58. Esta redução no resultado indica que provavelmente a estimação do valor da amostra retirada durante este processo não foi bem-sucedida, sendo superestimada ou subestimada. Porém, o valor de $RMSE^{cv}$ apresentou-se muito próximo ao valor da calibração ($RMSE^c$), assim como o valor de SEP, sendo estes parâmetros indicadores da qualidade do modelo, onde valores próximos da calibração, ou seja, $RMSE^{cv} \cong RMSE^c$, e valores de SEP próximos do RMSE, são indicadores de bons

modelos. Portanto pode se considerar que o valor de R^2 da fase de calibração de 0,43 é considerado como aceitável e o modelo possui boas características para estimar o teor de K foliar com base na utilização do espectro de reflectância.

Outro importante parâmetro que reforça tal conclusão é o Bias. Esta medida é desejável que apresente valor próximo de 0 (zero), conforme obtido durante a etapa da calibração do modelo, e indica se o modelo apresenta a tendência de superestimar ou subestimar a amostra, neste caso a amostra retirada durante o processo de calibração cruzada. O resultado de Bias de 0,07 aponta que o modelo, provavelmente, não tenderá a superestimar o resultado.

Após a etapa da validação cruzada o modelo foi testado avaliando a capacidade de predição de novas amostras que não participaram na construção do modelo PLSR, sendo utilizado as curvas espectrais referentes às amostras de concentração de K foliar obtido em laboratório.

Nesta fase observa-se que o modelo manteve-se com boa qualidade, apresentando aumento no valor de R^2 para 0,57 aproximando da etapa de calibração. O valor do $RMSEP$ não apresentou aumento substancial indicando a estabilidade do modelo obtido. De maneira análoga, observou-se este comportamento para o SEP^p , com valor extremamente próximo ao $RMSEP$. Com relação ao Bias, o mesmo manteve-se com valor próximo de 0 (zero) sendo de -0,47, indicando que o modelo, provavelmente, pode apresentar subestimação do teor de K foliar, porém, valores ainda muito próximo das amostras de laboratório.

Zhai Y. et al., (2012) trabalhando com dados de reflectância de folhas de diferentes espécies vegetais como arroz, milho, soja, obtiveram bons resultados no modelo PLSR para estimação de K, encontrando resultados na fase da calibração cruzada, para o coeficiente de determinação (R^2), de 0,50 e durante a fase de predição de 0,54. Os autores concluíram que os dados de reflectância apresentam elevado potencial para predição de nutriente foliar a partir de modelos PLSR.

Outro ponto importante a ser considerado é o coeficiente de correlação (r) sendo observado que, durante a etapa de predição, o mesmo apresentou valor muito próximo ao da calibração, sendo de 0,77 para a primeira etapa e 0,76 para a segunda, reforçando os bons resultados obtidos.

Resultados semelhantes foram encontrados por Zhang et al., (2013), onde os mesmos obtiveram valor de coeficiente de correção de 0,72 durante a etapa de calibração e 0,70 para a predição, utilizando do método PLSR para estimar a concentração de K foliar em colza a

partir de dados de reflectância de um sensor hiperespectral imageador. Os autores concluíram que é possível a utilização de dados hiperespectrais como uma ferramenta de para estimar nutrientes *in situ* em amostras de plantas vivas de forma não destrutiva.

Na Figura 19 encontra-se os coeficientes da regressão PLSR para predição da concentração de K foliar em plantas de milho.

Observa-se que os maiores coeficientes situaram-se na região do espectro correspondente a banda verde e azul e vermelha, sendo estas fortemente marcada pela presença dos pigmentos foliares como, por exemplo, as clorofilas, carotenoides e também, em menor intensidade, por compostos orgânicos de alto peso molecular, indicando que tais regiões apresentam boas propriedades e influência no modelo PLSR obtido.

Com relação a região do infravermelho próximo, nota-se que em próximo a 1.150 nm foi maior a contribuição no modelo, conseqüentemente, apresentando os maiores valores dos coeficientes, por outro lado, entre 1.000 a 1.100 nm, observou-se que foram as menores contribuições, indicando que esta porção não apresenta boas características para estimação de K foliar. De maneira análoga, porém com menor intensidade, as faixas espectrais entre 783 a 1.000 nm não contribuiu satisfatoriamente.

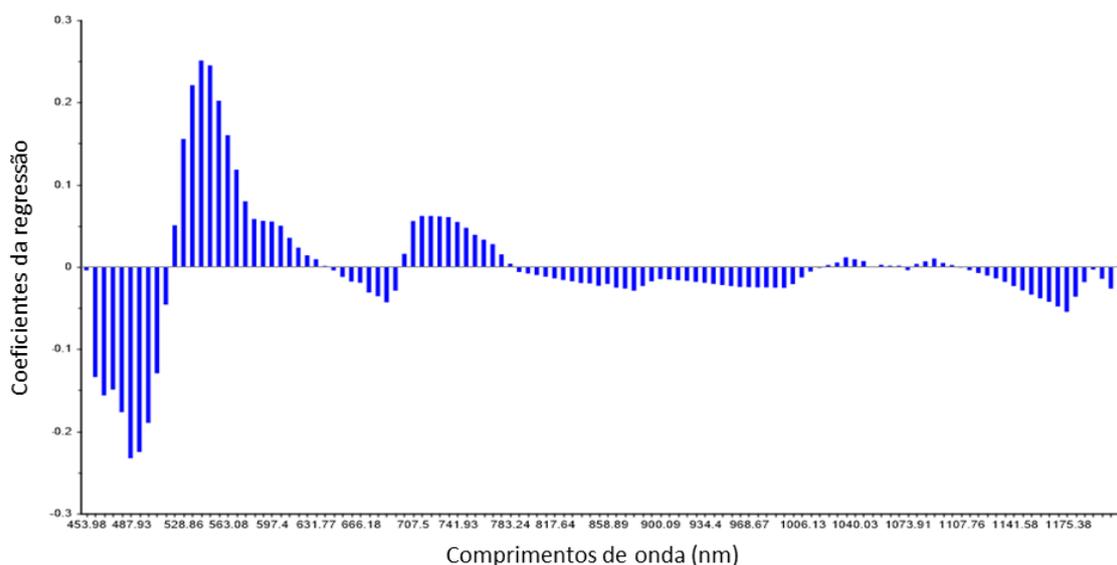


Figura 19 - Coeficientes de regressão do modelo PLSR para predição de K foliar em milho.

Os valores preditos para K foliar, a partir do modelo PLSR gerado, encontram-se na Tabela 24. Observa-se que o modelo apresentou boa capacidade de predição do K foliar quando comparado com os valores de referência, porém, alguns tratamentos apresentaram

considerável variação, especialmente o tratamento T-9, com maior diferença em relação ao valor de referência e, com menor intensidade o T-7.

Por outro lado, nota-se que para o teor de K foliar no tratamento T-2 e T-6 foram precisamente estimados com base no modelo PLSR construído utilizando o espectro de reflectância, sendo a diferença entre a referência e o estimado de -0,83 e 0,89 g kg⁻¹.

Tabela 24. Valores de referência do teor de K e os valores estimados pelo modelo PLSR (em g kg⁻¹).

Tratamentos	Estimado (a)	Referência (b)	Diferença (b – a)
T-2 - Bloco 4	25,34	24,51	-0,83
T-5 - Bloco 4	24,43	19,93	-4,50
T-6 - Bloco 4	27,85	28,74	0,89
T-7 - Bloco 4	46,20	41,02	-5,18
T-8 - Bloco 4	34,69	37,43	2,74
T-9 - Bloco 4	32,95	45,74	12,79
T-10 - Bloco 4	36,67	40,55	3,88
T-11 - Bloco 4	39,95	37,69	-2,26
T-12 - Bloco 4	40,89	37,64	-3,25

Para contornar estes pontos limitantes do processo e melhorar a capacidade de predição dos modelos há necessidade em utilizar maiores números de leituras espectrais associado com leituras em laboratório do elemento em estudo, embora o número de leituras e amostras utilizados na análise é considerado como adequado para o procedimento multivariado empregado, o maior número de amostras favorece a etapa de calibração e validação do modelo, uma vez que o mesmo possui um “range” maior para a construção e estimativa da amostra retirada nas etapas mencionadas acima.

Com isso, seguramente, os parâmetros de qualidade do modelo (coeficiente de correlação, R², RMSE, Bias e SEP) deverão melhorar e, conseqüentemente, estimado com maior precisão novas amostras que não participaram nas etapas iniciais.

Deste modo, pode-se concluir que diferentes sensores e produtos do sensoriamento remoto aliados a técnicas estatísticas avançadas possibilitam o conhecimento, identificação e quantificação da condição imposta as plantas, neste caso, por diferentes níveis de fertilidade de K nas parcelas experimentais, contribuindo para o rápido manejo evitando maiores perdas na produtividade.

6. CONCLUSÃO

A hipótese fixada neste trabalho foi atendida podendo ser concluído que a utilização de câmeras fotográficas digitais acopladas ao VANT, espectrorradiômetro em solo e o sensor imageador hiperespectral AisaFENIX possuem a capacidade de identificação, discriminação e quantificação da deficiência de K na cultura do milho, porém, não foi possível a identificação do tratamento denominado de “fome oculta” por meio da estatística univariada através de teste de comparação de médias com os IV's.

De modo geral, os IV's obtidos por câmeras digitais acopladas ao VANT apresentaram elevada capacidade na diferenciação dos tratamentos com deficiência (T-3) e o tratamento padrão (T-12), na grande maioria das datas de avaliações, destacando os IV's que utilizaram a banda do vermelho do espectro eletromagnético. Para os IV's obtido pelo espectrorradiômetro e o sensor AisaFENIX, os mesmos não apresentaram potencial em diferenciar os tratamentos, salvo o estágio de desenvolvimento V8 para o GNDVI, GNIR e GRVI obtido pelo espectrorradiômetro, sendo estes significantes entre o tratamento T-3 e T-12.

O comportamento espectral das plantas por meio do espectrorradiômetro não apresentou grandes variações nos estádios iniciais de desenvolvimento, sendo observado maior amplitude nos estádios mais avançados principalmente em V8 e R5.

Os métodos estatísticos multivariados permitiram a discriminação do tratamento T-2, o T-6 (“fome oculta”) e o tratamento padrão de adubação (T-12).

A modelagem dos IV's obtidos por câmeras digitais acopladas ao VANT e as curvas de reflectância pelo sensor AisaFENIX para predição de K foliar apresentaram elevado potencial na estimativa deste elemento. De maneira análoga, a predição da produtividade foi obtida com sucesso a partir de dados do sensor AisaFENIX.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ABER, J. S.; MARZOLFF, I.; RIES, J. B. **Small-format aerial photography: Principles, techniques and geoscience applications**. Elsevier, 2010.

AICARDI, I.; CHIABRANDO, F.; LINGUA, A.; NOARDO, F.; PIRAS, M.; VIGNA, B. A methodology for acquisition and processing of thermal data acquired by UAVs: a test about subfluvial springs' investigations. **Geomatics, Natural Hazards and Risk**, v. 8, n. 1, 2016.

ALDRICH, S. R.; SCOTT, W. O.; LENG, E. R. **Modern corn production**. 2.ed. Champaign: A & L Publication, 1982.

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.

ASSUNÇÃO, G. V.; FORMAGGIO, A. R. **O Sensoriamento Remoto Na Agricultura: Conceitos Básicos, Metodologias E Aplicações**. São José dos Campos, INPE. 217 p., 1989.

BARROS, M.; ARCHELA, R.; BARROS, O.; GRATÃO, L. Atlas Ambiental de Londrina. **Projeto de Pesquisa**, n. 05058/08, 2008.

BAUER, Marvin E. The role of remote sensing in determining the distribution and yield of crops. **Advances in Agronomy**, v. 27, p. 271-304, 1975.

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

BEMIS, S. P.; MICKLETHWAITE, S.; TURNER, D.; JAMES, M. R.; AKCIZ, S.; THIELE, S. T.; BANGASH, H. A. Ground-based and UAV-based photogrammetry: A multi-scale, high-resolution mapping tool for structural geology and paleoseismology. **Journal of Structural Geology**, v. 69, p. 163-178, 2014.

BERNI, J. A. J.; ZARCO-TEJADA, P. J.; SUAREZ, L.; FERERES, E. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722-738, 2009.

BERNI, J. A. J.; ZARCO-TEJADA, P. J.; SUAREZ, L.; GONZALEZ-DUGO, V.; FERERES, E. Remote sensing of vegetation from UAV platforms using lightweight multispectral and thermal imaging sensors. **Int. Arch. Photogramm. Remote Sens. Spatial Inform. Sci**, v. 38, n. 6, 2009.

BIRTH, G. S.; MCVEY G. R. Measuring color of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, v. 60, p. 640-649, 1968.

BO S.; JONSSON, A.; BÖRJESSON, T. Use of near infrared reflectance spectroscopy to predict nitrogen uptake by winter wheat within fields with high variability in organic matter. **Plant Soil**. v. 269, p. 251–258, 2005.

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.

CAMPBELL, J. B. **Introduction to remote sensing**, ed. 4. 2007, p. 1-621.

CANTARELLA, H. (Ed.). **Cultura do milho – fatores que afetam a produtividade**. Piracicaba: Potafós, 1993. p. 147-196.

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 Ciencia do Solo**, v. 37, n. 4, 2013.

CHEN, L.; LIN, L.; CAI, G.; SUN, Y.; HUANG, T.; WANG, K.; DENG, J. Identification of nitrogen, phosphorus, and potassium deficiencies in rice based on static scanning technology and hierarchical identification method. **PLoS one**, v. 9, n. 11, p. e113200, 2014.

CHEN, L.; QI, X.; ZHANG, X.; LI, Q.; ZHANG, Y. Effect of agricultural land use changes on soil nutrient use efficiency in an agricultural area, Beijing, China. **Chinese Geographical Science**, v. 21, n. 4, p. 392-402, 2011.

CHENG, Y.; HU, C.; WANG, C.; YU, G. Physiological response and spectral characteristics of summer corn under nutrient stress condition. **Resources Science**. p. 54–58, 2002.

COELHO, A. M.; ALVES, V. M. C. Adubação fosfatada na cultura do milho. In: YAMADA, T.; ABDALLA, S. R. S. **Fósforo na agricultura brasileira**. Piracicaba, Potafos, 2004. p. 243-283.

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, p.1659-1663, 1987.

COMPANHIA NACIONAL DE ABASTECIMENTO – CONAB. **Acompanhamento da safra brasileira de grãos**, v. 4 Safra 2016/17, n. 5 – Quinto levantamento. Brasília: Conab, Fevereiro, 2017. 166 p.

COOMER, T. D. **Effect of Potassium Deficiency on Uptake and Partitioning in the Cotton (*Gossypium hirsutum* L.) Plant and Detection by a Crop Reflectance Sensor**. 2016. Tese de doutorado - University of Arkansas - EUA.

CRUSIOL, L. G. T.; NANNI, M. R.; SILVA, G. F. C.; FURLANETTO, R. H.; GUALBERTO, A. A. da S.; GASPAROTTO, A. de C.; PAULA de M. N. Semi professional digital camera calibration techniques for Vis/NIR spectral data acquisition from an unmanned aerial vehicle. **International Journal of Remote Sensing**, p. 1-21, 2016.

D'OLEIRE-OLTMANN, S.; MARZOLFF, I.; PETER, K.; RIES, J. Unmanned Aerial Vehicle (UAV) for Monitoring Soil Erosion in Morocco. **Remote Sensing**, v. 4, n. 11, p. 3390-3416, 2012.

DEL POZO, S.; RODRÍGUEZ-GONZÁLVEZ, P.; HERNANDEZ-LOPEZ, D.; FELIPEGARCIA, B. Vicarious radiometric calibration of a multispectral camera on board an unmanned aerial system. **Remote Sensing**, v. 6, p. 1918-1937, 2014.

DIBB, D. W.; THOMPSON, W. R. Interaction of potassium with other nutrients. **Potassium in agriculture**, (*potassiuminagri*), p. 515-533, 1985.

DIBB, D. W.; WELCH, L. F. Corn growth as affected by ammonium vs. nitrate absorbed from soil. **Agronomy Journal**, v. 68, n. 1, p. 89-94, 1976.

DOS SANTOS, H. G.; JACOMINE, P. K. T.; DOS ANJOS, L. H. C.; DE OLIVEIRA, V. A., DE OLIVEIRA, J. D.; COELHO, M. R.; CUNHA, T. D. Sistema brasileiro de classificação de solos. **Embrapa Solos-Livros técnicos (INFOTECA-E)**, 2006.

ESTADOS UNIDOS. Department of Agriculture. **USDA.gov - United States Department of Agriculture**. Disponível em: <http://www.usda.gov> (Acesso em 10/11/2017).

EMBRAPA - Embrapa Solos. **Manual de análises químicas de solos, plantas e fertilizantes**. Brasília: Embrapa Informação Tecnológica; Brasília, DF: Embrapa Solos, 2009. 627p.

FAGERIA, N. K. Ionic interactions in rice plants from dilute solutions. **Plant and Soil**, v. 70, n. 3, p. 309-316, 1983.

FAGERIA, N. K.; GHEYI, H. R. **Efficient crop production**. Campina Grande: UFPB, 1999. 548 p.

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

FANCELLI, A. L.; DOURADO NETO, D. **Produção de milho**. Guaíba: Agropecuária, 2000. 360 p.

FERNANDES, L. A.; VASCONCELLOS, C. A.; FURTINI NETO, A. E.; ROSCOE, R.; GUEDES, G. A. de A. Preparo do solo e adubação nitrogenada na produção de grãos e matéria seca e acúmulo de nutrientes pelo milho. **Pesquisa Agropecuária Brasileira**, v. 34, n. 9, p. 1691-1698, 1998.

FERREIRA, M. M.; ANTUNES, A. M.; MELGO, M. S.; VOLPE, P. L. Quimiometria I: calibração multivariada, um tutorial. **Química Nova**, v. 22, n. 5, p. 724-731, 1999.

FERWERDA, J. G.; SKIDMORE, A. K. Can nutrient status of four woody plant species be predicted using field spectrometry?. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 62, n. 6, p. 406-414, 2007.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. São Paulo, SP: Oficina de Textos, 3ª ed., 2011. 128p.

FONSECA, D. & FERNANDES, J. (2004). **Detecção Remota**. 1ª. ed. Lisboa: Lidel. ISBN: 972-757-292-8. INE. Instituto Nacional de Estatística. Recenseamentos Gerais da Agricultura – Dados comparativos 1989-1999.

GAMBOA, A. **La fertilización del maíz**. Berna: Instituto Internacional de la Potasa, 1980. 72p. (Boletín II P, 5).

GASPAROTTO, A. de C. **Obtenção de imagens digitais e espectrometria da cultura do milho e sua relação com produtividade em diferentes doses de nitrogênio**. 107 p. Dissertação (Mestrado em Agronomia) – Universidade Estadual de Maringá (UEM), Maringá, 2014.

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

GEHRKE, R.; A. GREIWE. RGBI images with UAV off-the-shelf compact cameras: an investigations of linear sensor characteristics. **EARSeL eProceedings** Special Issue, 34th EARSeL Symposium, Warsaw, Jun. 16-20, p. 53-58, 2014.

GEIPEL, J.; LINK, J.; CLAUPEIN, W. Combined spectral and spatial modeling of corn yield based on aerial images and crop surface models acquired with an unmanned aircraft system. **Remote Sensing**, v. 6, n. 11, p. 10335-10355, 2014.

GETZIN, S.; NUSKE, R. S.; WIEGAND, K. Using unmanned aerial vehicles (UAV) to quantify spatial gap patterns in forests. **Remote Sensing**, v. 6, n. 8, p. 6988-7004, 2014.

GIRMA, K.; MOSALI, J.; RAUN, W. R.; FREEMAN, K. W.; MARTIN, K. L.; SOLIE, J. B.; STONE, M. L. Identification of optical spectral signatures for detecting cheat and ryegrass in winter wheat. **Crop Science**, v. 45, n. 2, p. 477-485, 2005.

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.

GOEL, P. K.; PRASHER, S. O.; PATEL, R. M.; LANDRY, J. A.; BONNELL, R. B.; VIAU, A. A. Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. **Computers and Electronics in Agriculture**, v. 39, n. 2, p. 67-93, 2003.

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.

GUO, X.; ZHU, X.; LI, C.; WEI, Y.; YU, X.; ZHAO, G.; SUN, H. Hyperspectral Inversion of Potassium Content in Apple Leaves Based on Vegetation Index. **Agricultural Sciences**, v. 8, n. 08, p. 825, 2017.

GROSSMAN, Y. L.; USTIN, S. L.; JACQUEMOUD, S.; SANDERSON, E. W.; SCHMUCK, G.; VERDEBOUT, J. Critique of stepwise multiple linear regression for the extraction of leaf biochemistry information from leaf reflectance data. **Remote Sensing of Environment**, v. 56, n. 3, p. 182-193, 1996.

GRUHN, P.; GOLETTI, F.; YUDELMAN, M. **Integrated nutrient management, soil fertility, and sustainable agriculture: current issues and future challenges**, International Food Policy Research Institute, 2000. 38 p.

GUPTA, U. C. Boron nutrition of crops. **Advances in agronomy**, v. 31, p. 273-307, 1980.

HANSEN, P. M.; JØRGENSEN, J. R.; THOMSEN, A. Predicting grain yield and protein content in winter wheat and spring barley using repeated canopy reflectance measurements and partial least squares regression. **The Journal of Agricultural Science**, v. 139, n. 3, p. 307-318, 2002.

HANSEN, P. M.; SCHJOERRING, J. K. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. **Remote Sensing of Environment**, v. 86, n. 4, p. 542-553, 2003.

HANWAY, J. J. Corn growth and composition in relation to soil fertility: I. Growth of different plant parts and relation between leaf weight and grain yield. **Agronomy Journal**, v. 54, p. 145- 148, 1962.

HILL, W. E.; MORRILL, L. G. Boron, calcium, and potassium interactions in Spanish peanuts. **Soil Science Society of America Journal**, v. 39, n. 1, p. 80-83, 1975.

HOFFER, R.M. Biological and Physical Considerations in Applying Computer-Aided Analysis Techniques to Remote Sensor Data. In: SWAIN, P. H; DAVIS, S.M. **Remote Sensing: The Quantitative Approach**. New York: McGRAW-HILL, 1978. p. 227-289.

HONKAVAARA, E.; ARBIOL, R.; MARKELIN, L.; MARTINEZ, L.; CRAMER, M.; BOVET, S.; SCHLÄPFER, D. Digital airborne photogrammetry - A new tool for quantitative remote sensing? A state-of-the-art review on radiometric aspects of digital photogrammetric images. **Remote Sensing**, v. 1, n. 3, p. 577-605, 2009.

HONKAVAARA, E.; SAARI, H.; KAIVOSOJA, J.; PÖLÖNEN, I.; HAKALA, T.; LITKEY, P.; MÄKYNEN, J.; PESONEN, L. Processing and Assessment of Spectrometric, Stereoscopic Imagery Collected Using a Lightweight UAV Spectral Camera for Precision Agriculture. **Remote Sensing**, v. 5, n. 10, p. 5006-5039, 2013.

HUANG, Y.; LAN, Y.; HOFFMANN, W. C.; FRITZ, B. K. Development of an unmanned aerial vehicle based remote sensing system for site-specific management in precision agriculture. In: **Proceedings of the 9th International Symposium on Precision Agriculture**. Denver, CO. CDROM. 2008.

HUBER, D. M.; ARNY, D. C. Interactions of potassium with plant disease. In: INTERNATIONAL SIMPOSIUM ON POTASSIUM IN AGRICULTURE, 1985, Atlanta. **Proceeding...** Madison: American society of agronomy/Crop science society of America, Soil Science Society of America, 1985. p. 467-488.

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

HUNT, E. R.; CAVIGELLI, M.; DAUGHTRY, C. S. T.; MCMURTREY, J. E.; WALTHALL, C. L. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, n. 4, p. 359-378, 2005.

IAPAR – Instituto Agronômico do Paraná. Disponível em <<http://www.iapar.br/>>. Acesso em 06 set. 2017.

INOUE, Y.; MORINAGA, S.; TOMITA, A. A blimp-based remote sensing system for low-altitude monitoring of plant variables: A preliminary experiment for agricultural and ecological applications. **International Journal of Remote Sensing**, v. 21, n. 2, p. 379-385, 2000.

JAIN, N.; RAY, S. S.; SINGH, J. P.; PANIGRAHY, S. Use of hyperspectral data to assess the effects of different nitrogen applications on a potato crop. **Precision Agriculture**, v. 8, n. 4-5, p. 225-239, 2007.

JACKSON, R. D.; JONES, C. A.; UEHARA, G.; SANTO, L. T. Remote detection of nutrient and water deficiencies in sugarcane under variable cloudiness. **Remote Sensing of Environment**, v. 11, p. 327-331, 1981.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Parêntese Editora, São Paulo, 650 p., 2009.

JOHANSEN, C.; EDWARDS, D. G.; LONERAGAN, J. F. Interactions between potassium and calcium in their absorption by intact barley plants. I. Effects of potassium on calcium absorption. **Plant physiology**, v. 43, n. 10, p. 1717-1721, 1968.

JOINSON, S.; BRITTON, B.; BARNETT, S. et al. **Fujifilm IS Pro, third UV & IR camera**, DPREVIEW, 2007. Disponível em: <https://www.dpreview.com/news/2007/7/13/fujifilmispro> (Acesso em: 08/11/2017).

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.

KARIMI, Y.; PRASHER, S. O.; MCNAIRN, H.; BONNELL, R. B.; DUTILLEUL, P.; GOEL, P. K. Discriminant analysis of hyperspectral data for assessing water and nitrogen stresses in corn. **Transactions of the ASAE**, v. 48, n. 2, p. 805-813, 2005.

KARLEN, D. L.; FLANNERY, R. L.; SADLER, E. J. Aerial accumulation and partitioning of nutrients by corn. **Agronomy Journal**, v. 80, n. 2, p. 232-242, 1988.

KELCEY J.; LUCIEER, A. Sensor correction of a 6-BAND multispectral imaging sensor for uav remote sensing. **Remote Sensing**, v. 4, p. 1462-1493, 2012.

KENDOUL, F.; LARA, D.; FANTONI-COICHOT, I.; LOZANO, R. Real-time nonlinear embedded control for an autonomous quadrotor helicopter. **Journal of Guidance Control and Dynamics**, v. 30, n. 4, p. 1049-1061, 2007.

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.

KOVALENKO, I. V.; RIPPKE, G. R.; HURBURGH, C. R. Determination of amino acid composition of soybeans (*Glycine max*) by near-infrared spectroscopy. **Journal of agricultural and food chemistry**, v. 54, n. 10, p. 3485-3491, 2006.

LALIBERTE, A. S.; GOFORTH, M. A.; STEELE, C. M.; RANGO, A. Multispectral remote sensing from unmanned aircraft: image processing workflows and applications for rangeland environments. **Remote Sensing**, v. 3, p. 2529-2251, 2011.

LALIBERTE, A. S.; HERRICK, J. E.; RANGO, A. Acquisition, orthorectification, and object-based classification of unmanned aerial vehicle (UAV) imagery for rangeland monitoring. **Photogrammetric Engineering & Remote Sensing**, v. 76, n. 6, p. 661-672, 2010.

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.

LELONG, C. C. D.; BURGER, P.; JUBELIN, G.; ROUX, B.; LABBÉ, S. BARET, F. Assessment of unmanned aerial vehicles imagery for quantitative monitoring of wheat crop in small plots. **Sensors**, v. 8, n. 5, p. 3557-3585, 2008.

LEWIS, G. Evaluating the use of a low-cost unmanned aerial vehicle platform in acquiring digital imagery for emergency response. **Geomatics solutions for disaster management**, p. 117-133, 2007.

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

LIEBMANN, B.; FRIEDL, A.; VARMUZA, K. Applicability of nearinfrared spectroscopy for process monitoring in bioethanol production. **Biochemical engineering journal**, v.52, p.187193, 2010.

LILLESAND, T. M.; KIEFER, R. W. **Remote Sensing and Image Interpretation**, 3rd. ed. John Wiley and Sons, New York, 1994, 750 p. ISBN: 0-471-30575-8 (pb).

LIMA, E. D. V.; ARAGÃO, C. A.; MORAIS, O. M.; TANAKA, R.; GRASSI FILHO, H. Adubação NK no desenvolvimento e na concentração de macronutrientes no florescimento do feijoeiro. **Scientia Agricola**, v. 58, n. 1, p. 125-129, 2001.

LIN, YI.; HYYPPA, J.; JAAKKOLA, A. Mini-UAV-borne LIDAR for fine-scale mapping. **IEEE Geoscience and Remote Sensing Letters**, v. 8, n. 3, p. 426-430, 2011.

LUO, C.; XUE, L.; LIU, M. Nondestructive measurement of sugar content in navel orange based on Vis-NIR spectroscopy. **Computer and Computing Technologies in Agriculture IV**. p. 467-473, 2010.

MACHADO, C. T. T.; PATERNIANI, M. L. S. Origem, domesticação e difusão do milho. In: SOARES, A. C. et al. **Milho crioulo: conservação e uso da biodiversidade**. Rio de Janeiro: AS-PTA, 1998. 185 p.

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

MALAVOLTA, E.; CROCOMO, O. J. O potássio e a planta. In: YAMADA, T.; IGUE, K.; MUZILLI, O.; USHERWOOD, N. R., ed. **Potássio na agricultura brasileira**. Piracicaba, Instituto da potassa e fosfato, Instituto internacional da potassa, 1982. p.95-162.

MARTIN, M. E.; NEWMAN, S. D.; ABER, J. D.; CONGALTON, R. G. Determining forest species composition using high spectral resolution remote sensing data. **Remote Sensing of Environment**, v. 65, n. 3, p. 249-254, 1998.

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

MERINO, L.; CABALLERO, F.; MARTÍNEZ-DE-DIOS, J. R.; MAZA, I.; OLLERO, A. An Unmanned Aircraft System for automatic forest fire monitoring and measurement. **Journal of Intelligent & Robotic Systems**, v. 65, n. 4, p. 533-548, 2012.

MINASNY, B.; MCBRATNEY, A. B.; MALONE, B. P.; WHEELER, I. Digital mapping of soil carbon. **Advances in Agronomy**, v. 118, n. 3, p. 4, 2013.

MITCHELL, J. J.; GLENN, N. F.; ANDERSON, M. O.; HRUSKA, R. C.; HALFORD, A.; BAUN, C.; NYDEGGER, N. Unmanned aerial vehicle (UAV) hyperspectral remote sensing for dryland vegetation monitoring. In: **Hyperspectral Image and Signal Processing (WHISPERS), 2012 4th Workshop on**. IEEE, 2012. p. 1-10.

MONTEIRO, J. E. **Agrometeorologia dos cultivos: o fator meteorológico na produção agrícola**. 546 p. 2009.

MOREIRA, A. M. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4. ed. Viçosa, MG: UFV, 2011. 422 p. ISBN: 978-85-7269-381-3.

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.

NAES, T., ISAKSSON, T., FEARN, T., DAVIES, T. 2002. **A user-friendly guide to multivariate calibration and classification**. NIR Publications, Chichester, 344 pp, 2002.

NANNI, M. R. Dados radiométricos obtidos em laboratório e no nível orbital na caracterização e mapeamento de solos, 366p. **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.

NANNI, M. R.; DEMATTÊ, J. A. M. Spectral reflectance methodology in comparison to traditional soil analysis. **Soil Science Society of America Journal**, v. 70, n. 2, p. 393-407, 2006).

NASCIMENTO, R. J. A. **Monitoramento em tempo real de processos fermentativos por espectroscopia do infravermelho próximo (NIRS)**. 145 p. Dissertação (mestrado). Universidade Federal do Rio Grande do Norte, 2012.

NAVARRO, M. M. **SENSING DEVELOPMENT OF A SOYBEAN CANOPY UNDER P OR K NUTRITIONAL STRESS**. 125 p. Dissertação (mestrado). College of Agriculture at the University of Kentucky, 2012.

NEBIKER, S.; ANNEN, A.; SCHERRER, M.; OESCH, D. A light-weight multispectral sensor for micro UAV: Opportunities for very high resolution airborne remote sensing. **The international archives of the photogrammetry, remote sensing and spatial information sciences**, v. 37, n. B1, p. 1193-1199, 2008.

NEVES, N. A. **Determinação multiparamétrica da qualidade físicoquímica de vinhos tintos com uso de espectroscopia na região de infravermelho próximo**. 156 p. Dissertação (mestrado). Universidade Federal dos Vales do Jequitinhonha e Mucuri, 2012.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 4.ed. São Paulo - SP. Edgard Blucher, 388 p., 2010.

OSBORNE, S. L. Utilization of existing technology to evaluate spring wheat growth and nitrogen nutrition in South Dakota. **Communications in soil science and plant analysis**, v. 38, n. 7-8, p. 949-958, 2007.

OSBORNE, S. L.; SCHEPERS, J. S.; FRANCIS, D. 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.

PATERNIANI, E.; CAMPOS, M. S. Melhoramento do milho. In: BORÉM, A. **Melhoramento de espécies cultivadas**. Viçosa: UFV, 1999. 817 p.

PATIL, A. G.; OAK, M. D.; TAWARE, S. P.; TAMHANKAR, S. A.; RAO, V. S. Nondestructive estimation of fatty acid composition in soybean [*Glycine max* (L.) Merrill] seeds using Near-Infrared Transmittance Spectroscopy. **Food chemistry**, v. 120, n. 4, p. 1210-1217, 2010.

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

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

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

PONZONI, F. J.; DE, J. L.; GONCALVES, M. Spectral features associated with nitrogen, phosphorus, and potassium deficiencies in *Eucalyptus saligna* seedling leaves. **International Journal of Remote Sensing**, v. 20, n. 11, p. 2249-2264, 1999.

PONZONI, F. J.; GALVÃO, L. S.; EPIPHANIO, J. C. N. Influência da resolução espacial sobre a quantificação de áreas não florestadas em ambiente Amazônico. In: SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10, 2001, **Anais...**, Foz do Iguaçu: INPE, 2001. p. 1713 -1720.

PRIMICERIO, J.; GENNARO, S. F. D.; FIORILLO, E.; GENESIO, L.; LUGATO, E.; MATESE, A.; VACCARI, F. P. A flexible unmanned aerial vehicle for precision agriculture. **Precision Agriculture**, v. 13, n. 4, p. 517-523, 2012.

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

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

RITCHIE, G. L.; SULLIVAN, D. G.; PERRY C. D.; HOOK, J. E.; BEDNARZ C. W. Preparation of a low cost digital camera system for remote sensing. **Applied Engineering in Agriculture**, v. 24, n. 6, p. 885-894, 2008.

RITCHIE, S.; HANWAY, J. J. **How a corn plant develops**. Ames: Iowa State University of Science and Technology/ Cooperative Extension Service, 1989. (Special Report, 48).

ROBERTS, T. L. Potássio na agricultura brasileira. **Piracicaba, Potafos**, 841 p. 2005.

RÖMISCH-MARGL, L.; SPIELBAUER, G.; SCHÜTZENMEISTER, A.; SCHWAB, W.; PIEPHO, H. P.; GENSCHER, U.; GIERL, A. Heterotic patterns of sugar and amino acid components in developing maize kernels. **Theoretical and applied genetics**, v. 120, n. 2, p. 369-381, 2010.

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

ROSALES, A.; GALICIA, L.; OVIEDO, E.; ISLAS, C.; PALACIOS-ROJAS, N. Near-infrared reflectance spectroscopy (NIRS) for protein, tryptophan, and lysine evaluation in

quality protein maize (QPM) breeding programs. **Journal of agricultural and food chemistry**, v. 59, n. 20, p. 10781-10786, 2011.

ROUSE, J. W. Monitoring the vernal advancement of retrogradation of natural vegetation. **Final Report, Type III, NASA/GSFC**, Greenbelt, MD, p.371. 1974.

SALAZAR, L.; KOGAN, F.; ROYTMAN, L. Using vegetation health indices and partial least squares method for estimation of corn yield. **International Journal of Remote Sensing**, v. 29, n. 1, p. 175-189, 2008.

SAMBORSKI, S. M.; TREMBLAY, N.; FALLON, E. Strategies to make use of plant sensors-based diagnostic information for nitrogen recommendations. **Agronomy Journal**, v. 101, n. 4, p. 800-816, 2009.

SAYRE, J. D. Mineral accumulation in corn. **Plant Physiology**, v. 23, n. 3, p. 267-281, 1948.

SEVERTSON, D.; CALLOW, N.; FLOWER, K.; NEUHAUS, A.; OLEJNIK, M.; NANSEN, C. Unmanned aerial vehicle canopy reflectance data detects potassium deficiency and green peach aphid susceptibility in canola. **Precision Agriculture**, v. 17, n. 6, p. 659-677, 2016.

SILVA JÚNIOR, M.C.; PINTO, F.A.C.; QUEIROZ, D.M. et al. Utilização de imagens multiespectrais para detectar diferentes níveis nutricionais na forrageira *Brachiaria decumbens*. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13, 2007, Florianópolis. **Anais...** Florianópolis: INPE: 2007. P. 401-406.

SLAUGHTER, D. C.; LANINI, W. T.; GILES, D. K. Discriminating weeds from processing tomato plants using visible and near-infrared spectroscopy. **Transactions of the ASAE**, v. 47, n. 6, p. 1907, 2004.

SOUZA, A. M. D.; BREITKREITZ, M. C.; FILGUEIRAS, P. R.; ROHWEDDER, J. J. R.; POPPI, R. J. Experimento didático de quimiometria para calibração multivariada na determinação de paracetamol em comprimidos comerciais utilizando espectroscopia no infravermelho próximo: um tutorial, parte II. **Química Nova**, v. 36, n. 7, p. 1057-1065, 2013.

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, 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.

STIPP, S. R.; YAMADA, T. **Nutrição e adubação do milho**. Informações Agronômicas, Piracicaba, v. 44, p. 3-6, dez. 1988.

SUGIURA, R.; NOGUCHI, N.; ISHII, K.; TERAOKA, H. The development of remote sensing system using unmanned helicopter. In: **Automation Technology for Off-Road Equipment Proceedings of the 2002 Conference**. American Society of Agricultural and Biological Engineers, 2002. p. 120.

SWAIN, K. C.; JAYASURIYA, H. P. W.; SALOKHE, V. M. Suitability of low-altitude remote sensing images for estimating nitrogen treatment variations in rice cropping for precision agriculture adoption. **Journal of Applied Remote Sensing**, v. 1, n. 1, p. 013547, 2007.

TAJUDDIN, T.; WATANABE, S.; MASUDA, R.; HARADA, K.; KAWANO, S. Application of near infrared transmittance spectroscopy to the estimation of protein and lipid contents in single seeds of soybean recombinant inbred lines for quantitative trait loci analysis. **Journal of near infrared spectroscopy**, v. 10, n. 4, p. 315-325, 2002.

TALLADA, J. G.; PALACIOS-ROJAS, N.; ARMSTRONG, P. R. Prediction of maize seed attributes using a rapid single kernel near infrared instrument. **Journal of cereal science**, v. 50, n. 3, p. 381-387, 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.

TIAN, Y. C.; YAO, X.; YANG, J.; CAO, W. X.; HANNAWAY, D. B.; ZHU, Y. Assessing newly developed and published vegetation indices for estimating rice leaf nitrogen concentration with ground-and space-based hyperspectral reflectance. **Field Crops Research**, v. 120, n. 2, p. 299-310, 2011.

TREMBLAY, N.; WANG, Z.; MA, B. L.; BELEC, C.; VIGNEAULT, P. A comparison of crop data measured by two commercial sensors for variable-rate nitrogen application. **Precision Agriculture**, v. 10, n. 2, p. 145, 2009.

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

USSYSHKIN, V.; THERIAULT, L. Airborne lidar: advances in discrete return technology for 3D vegetation mapping. **Remote Sensing**, v. 3, n. 3, p. 416-434, 2011.

VASCONCELLOS, C. A.; FORTES, J. M.; FERNANDES, J.; SANTOS, Z. T.; BASSO, L. C.; MALAVOLTA, E. Ocorrência de putrescina em folhas de milho, var. "Piranão" deficientes em potássio. **Revista Ceres**, v. 24, n. 131, p. 88-93, 1983.

VASUKI, Y.; HOLDEN, E.; KOVESI, P.; MICKLETHWAITE, S. Semi-automatic mapping of geological structures using UAV-based photogrammetric data: An image analysis approach. **Computers & Geosciences**, v. 69, p. 22-32, 2014.

WALLACE, L.; LUCIEER, A.; WATSON, C.; TURNER, D. Development of a UAV-LiDAR system with application to forest inventory. **Remote Sensing**, v. 4, n. 6, p. 1519-1543, 2012.

WANG H.; LI M.; ZHANG Y. Determination of Corn Nutrient Status under N&K Stressed Condition Using Hyperspectral Analysis. **Computer and Computing Technologies in Agriculture V. Advances in Information and Communication Technology**, v. 369, p. 302-313, 2012.

WANG, D.; DOWELL, F. E.; LACEY, R. E. Single wheat kernel color classification using neural networks. **Transactions of the ASAE**, v. 42, n. 1, p. 233, 1999.

WANG, H. W. **Partial Least Squares Regression Method and Applications**. National Defense Industry Press, p. 201-206, 1999.

WANG, L.; BAI, Y. L.; YANG, L. P. Spectral response and diagnosis of phosphorus nutrition in corn. **Plant Nutrition and Fertilizer Science**, v. 13, n. 5, p. 802-808, 2007.

WANG, L.; BAI, YOU-LU. Nutrients change and spectral response of spring corn leaf for varying amounts of potassium fertilization. **JOURNAL OF REMOTE SENSING-BEIJING**, v. 11, n. 5, p. 641, 2007.

WEST, J. S.; BRAVO, C.; OBERTI, R.; LEMAIRE, D.; MOSHOU, D.; MCCARTNEY, H. A. The potential of optical canopy measurement for targeted control of field crop diseases. **Annual review of Phytopathology**, v. 41, n. 1, p. 593-614, 2003.

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.

WITTKOP, B.; SNOWDON, R. J.; FRIEDT, W. New NIRS calibrations for fiber fractions reveal broad genetic variation in *Brassica napus* seed quality. **Journal of agricultural and food chemistry**, v. 60, n. 9, p. 2248-2256, 2012.

WU, J.; WANG, D.; BAUER, M. E. Assessing broadband vegetation indices and QuickBird data in estimating leaf area index of corn and potato canopies. **Field crops research**, v. 102, n. 1, p. 33-42, 2007.

XIANG, H.; TIAN, L. Development of a low-coast agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV). **Biosystems Engineering**, v. 108, p. 174-190, 2011.

YANG, C.; EVERITT, J. H.; BRADFORD, J. M.; MURDEN, D. Airborne hyperspectral imagery and yield monitor data for mapping cotton yield variability. **Precision Agriculture**, v. 5, n. 5, p. 445-461, 2004.

Yara N-sensor. Disponível em: <http://www.yarabrasil.com.br/nutricao-plantas/ferramentas-servicos/n-sensor/> (acesso em 07/11/2017).

YE, X.; SAKAI, K.; SASAO, A.; ASADA, S. I. Potential of airborne hyperspectral imagery to estimate fruit yield in citrus. **Chemometrics and Intelligent Laboratory Systems**, v. 90, n. 2, p. 132-144, 2008.

ZAMAN-ALLAH, M.; VERGARA, O.; ARAUS, J. L.; TAREKEGNE, A.; MAGOROKOSHO, C.; ZARCO-TEJADA, P. J. Unmanned aerial platform-based multispectral imaging for field phenotyping of maize. **Plant methods**, v. 11, n. 1, p. 35, 2015.

ZARCO-TEJADA, P. J.; GONZALEZ-DUGO, V.; BERNI, J. A. J. Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. **Remote Sensing of Environment**, v. 117, p. 322-337, 2012.

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, J.; YANG, C.; SONG, H.; HOFFMANN, W. C.; ZHANG, D.; ZHANG, G. Evaluation of an airborne remote sensing platform consisting of two consumer-grade cameras for crop identification. **Remote Sensing**, v. 8, n. 3, p. 257, 2016.

APÊNDICE A

Tabela 25. Características químicas do solo no ano de 2015 das parcelas experimentais referente aos tratamentos estudados.

Trat.	Rep	Profund. cmpH.....		C _{org}g dm ⁻³	M.O	P _{mehlich-1}mg dm ⁻³	P _{resin}
			0.01 mol L ⁻¹ CaCl ₂	SMP				
T-2	1	0-20	4,98	5,88	15,58	26,86	9,19	18,27
T-2	2	0-20	5,03	5,97	14,99	25,85	11,20	21,91
T-2	3	0-20	4,75	5,79	12,93	22,30	8,43	22,59
T-2	4	0-20	4,92	5,92	16,02	27,62	6,70	14,64
T-3	1	0-20	4,88	5,96	13,60	23,44	6,08	15,77
T-3	2	0-20	5,12	6,00	15,07	25,97	8,85	26,45
T-3	3	0-20	5,17	6,13	15,29	26,35	9,61	23,95
T-3	4	0-20	5,25	6,14	14,99	25,85	11,47	28,73
T-6	1	0-20	4,66	5,70	16,17	27,87	48,31	100,91
T-6	2	0-20	5,16	6,11	15,43	26,61	39,18	125,91
T-6	3	0-20	4,85	5,80	16,02	27,62	56,53	148,64
T-6	4	0-20	5,00	6,00	14,11	24,33	36,35	116,82
T-12	1	0-20	4,94	5,97	17,20	29,65	36,35	114,55
T-12	2	0-20	5,05	5,99	16,46	28,38	47,20	146,36
T-12	3	0-20	5,27	6,06	18,81	32,44	40,84	128,18
T-12	4	0-20	4,95	5,83	18,81	32,44	59,78	153,18

K _{mehlich-1}	Ca ²⁺	Mg ²⁺	Al ³⁺	H+Al	CEC _e (t)	CEC (T)	SB	V	m
.....cmolc dm ⁻³%.....	
0,10	2,41	0,85	0,62	4,79	3,98	8,15	3,36	41,21	15,59
0,10	2,30	0,87	0,56	4,36	3,83	7,62	3,27	42,85	14,64
0,10	2,17	0,75	0,66	5,27	3,68	8,29	3,02	36,44	17,94
0,08	2,44	0,88	0,58	4,59	3,98	7,99	3,40	42,54	14,57
0,04	2,16	0,82	0,60	4,40	3,63	7,43	3,03	40,74	16,54
0,11	2,93	1,05	0,52	4,22	4,61	8,31	4,09	49,20	11,28
0,07	2,45	0,95	0,53	3,68	4,01	7,16	3,48	48,59	13,22
0,07	3,09	1,17	0,47	3,64	4,80	7,97	4,33	54,30	9,80
0,09	2,09	0,75	0,81	5,79	3,74	8,72	2,93	33,62	21,64
0,08	2,93	1,13	0,55	3,76	4,69	7,90	4,14	52,44	11,72
0,08	2,56	0,96	0,65	5,21	4,25	8,81	3,60	40,87	15,29
0,09	2,82	1,08	0,54	4,22	4,53	8,21	3,99	48,61	11,91
0,36	2,44	0,78	0,53	4,36	4,11	7,93	3,58	45,08	12,91
0,46	2,65	0,89	0,50	4,27	4,50	8,27	4,00	48,40	11,11
0,38	3,57	1,29	0,45	3,96	5,69	9,21	5,24	56,96	7,90
0,35	2,86	0,96	0,53	5,05	4,70	9,22	4,17	45,23	11,28

Fonte: Dados cedidos da tese de doutorado da parceria EMBRAPA - USP.

APÊNDICE B

/*Arquivo de criação do dataset - filename busca os dados, libname é redução do nome para busca do arquivo, options especifica numero de colunas, "A" antes do comprimento de onda é a maneira correta pra o SAS entender a programação*/

```
filename dados dde 'clipboard';
libname c 'c:\analise discriminante';
options ls=256;
data c.dados;
  infile dados lrecl=40000;
  input amostra $ tratamento $

      A454 A461 A468 A474 A481 A488 A495 A502 A508
      A515 A522 A529 A536 A543 A549 A556 A563 A570
      A577 A584 A591 A597 A604 A611 A618 A625 A632
      A639 A646 A652 A659 A666 A673 A680 A687 A694
      A701 A708 A714 A721 A728 A735 A742 A749 A756
      A763 A769 A776 A783 A790 A797 A804 A811 A818
      A825 A831 A838 A845 A852 A459 A866 A873 A880
      A886 A893 A900 A907 A914 A921 A928 A934 A941
      A948 A955 A962 A969 A978 A984 A989 A995 A1000
      A1006 A1012 A1017 A1023 A1029 A1034 A1040 A1046 A1051
      A1057 A1063 A1068 A1074 A1080 A1085 A1091 A1096 A1102
      A1108 A1113 A1119 A1125 A1130 A1136 A1142 A1147 A1153
      A1158 A1164 A1170 A1175 A1181 A1187 A1192 A1198 A1204;
```

run;

```
proc stepdisc slentry=0.10;
  class tratamento;
  var
```

```
      A454 A461 A468 A474 A481 A488 A495 A502 A508
      A515 A522 A529 A536 A543 A549 A556 A563 A570
      A577 A584 A591 A597 A604 A611 A618 A625 A632
      A639 A646 A652 A659 A666 A673 A680 A687 A694
      A701 A708 A714 A721 A728 A735 A742 A749 A756
      A763 A769 A776 A783 A790 A797 A804 A811 A818
      A825 A831 A838 A845 A852 A459 A866 A873 A880
      A886 A893 A900 A907 A914 A921 A928 A934 A941
      A948 A955 A962 A969 A978 A984 A989 A995 A1000
      A1006 A1012 A1017 A1023 A1029 A1034 A1040 A1046 A1051
      A1057 A1063 A1068 A1074 A1080 A1085 A1091 A1096 A1102
      A1108 A1113 A1119 A1125 A1130 A1136 A1142 A1147 A1153
      A1158 A1164 A1170 A1175 A1181 A1187 A1192 A1198 A1204;
```

run;

```
  proc discrim data=c.dados;
  var
```

```
      A776 A735 A1063 A1170 A1017 A1142 A1057
      A1023 A625 A742 A549 A1175 A728 A646 A639
      A708 A1023;
```

```
class tratamento;
run;
```

```
%macro simula(corte,n_arq);
```

```

        title 'Análise discriminante com bandas';
filename dados dde 'clipboard';
libname c 'c:\analise discriminante';
data simula testa;
    set c.dados;
    aleat = ranuni(-2);
    where tratamento = 'T12' or tratamento = 'T2'    or
        tratamento= 'T6';
    if aleat > &corde then output testa;
        else output simula;
proc   discrim   data=simula   testdata=testa   testout=t&n_arq   noprint
out=s&n_arq;
    class tratamento;
    var

        A776 A735 A1063 A1170 A1017 A1142 A1057
        A1023 A625 A742 A549 A1175 A728 A646 A639
        A708 A1023;

run;
%mend;

%macro chama(start);
    %do start=1 %to 50;
        %simula(0.60,&start);
    %end;
%mend;

%chama();

data teste;
    set t1 t2 t3 t4 t5 t6 t7 t8 t9 t10
        t11 t12 t13 t14 t15 t16 t17 t18 t19 t20
        t21 t22 t23 t24 t25 t26 t27 t28 t29 t30
        t31 t32 t33 t34 t35 t36 t37 t38 t39 t40
        t41 t42 t43 t44 t45 t46 t47 t48 t49 t50;

run;

data simula;
    set s1 s2 s3 s4 s5 s6 s7 s8 s9 s10
        s11 s12 s13 s14 s15 s16 s17 s18 s19 s20
        s21 s22 s23 s24 s25 s26 s27 s28 s29 s30
        s31 s32 s33 s34 s35 s36 s37 s38 s39 s40
        s41 s42 s43 s44 s45 s46 s47 s48 s49 s50;

run;

* ---- Dados usados para teste (40%) -----;
title 'Teste com dados independentes do modelo';
proc freq data=teste;
    table tratamento*_into_ / chisq;
data teste;
    set teste;
    if tratamento = _into_ then correto = 'Sim';
        else correto = 'Não';
proc freq data=teste;
    table correto;
run;

* ---- Dados usados para modelo (60%) -----;
title 'Teste com dados usados no modelo';

```

```
proc freq data=simula;  
  table tratamento*_into_ / chisq;  
data simula;  
  set simula;  
  if tratamento = _into_ then correto = 'Sim';  
  else correto = 'Não';  
proc freq data=simula;  
  table correto;  
run;
```