

MARLEY LAMOUNIER MACHADO

**DETECÇÃO DE DOENÇAS DO FEIJÃO POR CARACTERÍSTICAS  
ESPECTRAIS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

VIÇOSA  
MINAS GERAIS – BRASIL  
2013

Ficha catalográfica preparada pela Seção de Catalogação e  
Classificação da Biblioteca Central da UFV

T

M149d Machado, Marley Lamounier, 1967-  
2013 Detecção de doenças de feijão por características espectrais  
/ Marley Lamounier Machado. – Viçosa, MG, 2013.  
xiv, 119f. : il. (algumas color.) ; 29 cm.

Inclui anexo.

Orientador: Francisco de Assis de Carvalho Pinto.

Tese (doutorado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Feijão - Doenças e pragas. 2. Análise espectral.  
3. Mofo-Branco. 4. Mancha-angular. I. Universidade Federal de  
Viçosa. Departamento de Engenharia Agrícola. Programa de  
Pós-Graduação em Engenharia Agrícola. II. Título.

CDD 22 ed. 635.65294

MARLEY LAMOUNIER MACILADO

**DETECÇÃO DE DOENÇAS DO FEIJÃO POR CARACTERÍSTICAS  
ESPECTRAIS**

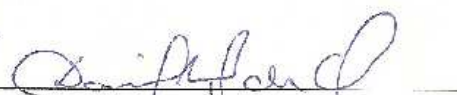
Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

APROVADA: 28 de Novembro de 2013.

  
Domingos Sarvio Magalhaes Valente

  
Nerilson Terra Santos

  
Rogério Faria Vieira

  
Daniel Marçal Queiroz  
(Coorientador)

  
Francisco de Assis Carvalho Pinto  
(Orientador)

*Rafael e Renilda,*

*Quero agradecer e honrar meus pais pelo amor e por me sustentar em oração.*

*Cleide, minha querida esposa, eu te amo.*

*Ingrid e Rafael Lamounier, meus filhotes amados.*

*Dedico a vocês.*

## **AGRADECIMENTOS**

Ao meu Senhor e Pai, o Deus todo poderoso e ao nosso Senhor e Salvador Jesus Cristo pela graça não merecida.

A Empresa de Pesquisa Agropecuária de Minas Gerais – EPAMIG, pela oportunidade e confiança na minha pessoa em participar deste curso.

A Universidade Federal de Viçosa - UFV e ao Departamento de Engenharia Agrícola, pela oportunidade e excelência na realização do curso.

A Fundação de Amparo à Pesquisa do Estado de Minas Gerais – FAPEMIG, pela bolsa concedida durante o Curso de Doutorado.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – Brasil (CNPq), pelos recursos disponibilizados para realização das pesquisas.

Ao professor Francisco de Assis de Carvalho Pinto, pelo ensino, orientação e empenho em relação ao desempenho das minhas atividades, além da amizade nos anos de convivência na UFV.

Ao professor Daniel Marçal de Queiroz pelos ensinamentos e receptividade no meu ingresso no curso.

Ao professor José Eustáquio de Souza Carneiro, pela colaboração e sugestões na condução dos trabalhos de campo.

Ao professor Haroldo Fernandes pelo apoio.

Aos pesquisadores da EPAMIG, Dr. Rogério Vieira e Dr. Trazilbo Jose pelo apoio e assessoria técnica na condução das atividades.

Aos funcionários da Fazenda Experimental de Oratórios, Luciano Jacob, Izza Paula, aos funcionários de campo Silvio e Silvio Martins e a todos os do corpo técnico e administrativo. Agradeço pelas ações solícitas e prontidão em ajudar.

A amiga e chefe, Dra. Maria Lélia pelo constante apoio e confiança.

Ao amigo Paulo Oliveira pelo apoio na estatística.

Agradecimento especial ao bolsista Ozires Ângelo e a estagiária Iara Arrighi pela presença constante e valentia em todos os momentos. Meu muito obrigado também

aos estagiários e bolsistas: Bruna do Valle, Anderson Cândido, Cristiano Zerbato, Renan Stanciola e Lucas Rocha, pela dedicação e boa vontade na execução das atividades. A todos os demais bolsistas que em algum momento contribuíram nas minhas atividades, agradeço.

Aos parceiros e amigos, Daniel Leite, Marcelo Marques e Lorena Temponi, meu muito obrigado. A todos os amigos da mecanização agrícola pelo constante apoio.

A minha irmã, sobrinhos, cunhados, tios, meus irmãos em Cristo e amigos.

A todos, MUITO OBRIGADO!

*E deu Deus a Salomão sabedoria, e muitíssimo entendimento, e largueza de coração, como a areia que está na praia do mar. E era a sabedoria de Salomão maior do que a sabedoria de todos os do oriente e do que toda a sabedoria dos egípcios (1 Reis 4:29-30). Falou Salomão das árvores, desde o cedro que está no Líbano até ao hissopo que nasce na parede; também falou dos animais e das aves, e dos répteis e dos peixes. E vinham de todos os povos a ouvir a sabedoria de Salomão, e de todos os reis da terra que tinham ouvido da sua sabedoria (1 Reis 4:33-34).*

**Minha primeira oração:**

Senhor, a sabedoria que vem de Ti excede todo o entendimento. Quero te agradecer pela sua sabedoria que foi ministrada aos meus orientadores, professores, pesquisadores, colegas de curso. O Senhor me proporcionou ser abençoado por cada um deles. Te louvo e agradeço por isso.

*Os vinte e quatro anciãos prostravam-se diante do que estava assentado sobre o trono, e adoravam o que vive para todo o sempre; e lançavam as suas coroas diante do trono, dizendo: Digno és, Senhor, de receber glória, e honra, e poder; porque tu criaste todas as coisas, e por tua vontade são e foram criadas (Apocalipse 4:10-11).*

**Minha segunda oração:**

Senhor, quero agradecer pela oportunidade de ter participado deste curso, e por ter me capacitado e ter me dado segurança em ir e vir, guardando minha vida e de meus familiares. Assim, se há alguma glória neste trabalho, faço como os anciãos diante do trono que lançavam suas coroas diante de Ti, pois nada teria se por Ti não me fosse dado. Que o Senhor Cresça e eu diminua!

## SUMÁRIO

<b>RESUMO</b> .....	ix
<b>ABSTRACT</b> .....	xii
<b>INTRODUÇÃO GERAL</b> .....	1
<b>BILBIOGRAFIA GERAL</b> .....	7

### **CAPÍTULO 1**

---

#### **AVALIAÇÃO DE MANCHA-ANGULAR DE FEIJÃO UTILIZANDO REFLECTÂNCIA HIPERSPECTRAL FOLIAR E DE DOSSEL**

RESUMO.....	10
ABSTRACT.....	11
INTRODUÇÃO.....	11
MATERIAL E MÉTODOS	
Condução dos experimentos.....	13
Aquisição de dados em campo.....	15
Determinação dos níveis de doença.....	17
Identificação da assinatura espectral.....	18
Identificação dos comprimentos de onda hiperespectrais por correlação multivariada.....	18
Identificação de comprimentos de onda hiperespectrais por regressão por Mínimos Quadrados Parciais (PLS).....	19
RESULTADOS.....	22
DISCUSSÃO.....	28
CONCLUSÃO.....	33
BIBLIOGRAFIA.....	33

## **CAPÍTULO 2**

---

### **ESTIMATIVA DE SEVERIDADE DO MOFO-BRANCO EM LAVOURAS DE FEIJÃO UTILIZANDO SENSORES HIPER E MULTIESPECTRAL**

RESUMO.....	36
ABSTRACT.....	37
INTRODUÇÃO.....	38
MATERIAL E MÉTODOS	
Condução dos experimentos.....	40
Aquisição de dados em campo.....	41
Identificação de comprimentos de onda hiperespectrais e bandas multiespectrais por regressão PLS.....	44
Índices de vegetação.....	46
Softwares.....	48
RESULTADOS.....	49
DISCUSSÃO.....	52
CONCLUSÃO.....	56
BIBLIOGRAFIA.....	56

## **CAPÍTULO 3**

---

### **DETECÇÃO MULTI-TEMPORAL DE MOFO-BRANCO DE FEIJÃO UTILIZANDO REFLECTÂNCIAS HIPERESPECTRAL FOLIAR**

RESUMO.....	61
ABSTRACT.....	62
INTRODUÇÃO.....	62
MATERIAL E MÉTODOS	
Condução dos experimentos.....	65
Determinação dos níveis de doença.....	66
Aquisição de dados em campo.....	66
Identificação de comprimentos de onda hiperespectrais por regressão PLS.....	67
Softwares.....	69

RESULTADOS.....	70
DISCUSSÃO.....	76
CONCLUSÃO.....	81
BILBIOGRAFIA.....	82
<b>CONCLUSÕES FINAIS.....</b>	<b>86</b>
<b>ANEXOS</b>	
a) Linearização e recorte de imagem.....	88
b) Amostragem das classes nas folhas do feijão.....	89
c) Seleção de amostras na forma aleatória.....	90
d) Função Discriminante Quadrática.....	92
e) Calculo do Índice Kappa e AFN.....	95
f) Seleção de amostras para usar regressão PLS .....	97
g) Identificação de outliers (z score robusto).....	100
h) Separa grupos de calibração e validação.....	101
i) Processa regressão PLS.....	104
j) Índices de vegetação Hiperespectrais.....	109
l) Índices de vegetação Multiespectrais.....	118

## RESUMO

MACHADO, Marley Lamounier, D.Sc., Universidade Federal de Viçosa, Novembro de 2013. **Deteção de doenças do feijão por características espectrais.** Orientador: Francisco de Assis de Carvalho Pinto. Coorientadores: Daniel Marçal de Queiroz e Trazilbo José de Paula Júnior.

O presente trabalho pretende testar a hipótese de que é possível detectar a presença de doenças fúngicas de feijoeiros, típicas de períodos de outono/inverno, utilizando reflectância de folhas e de dossel. Para isso, foram feitas análise do comportamento espectral das plantas infectadas pelas doenças em diversas datas do ciclo da cultura, construção de modelos matemáticos preditivos por métodos multivariados, teste de modelos existentes (índices de vegetação) e determinação dos comprimentos de onda mais representativos para a estimativa da severidade da doença. Foram implantados cinco experimentos em locais com histórico de mancha-angular (MA) e mofo-branco (MB). Dois experimentos de mancha-angular e um de mofo-branco foram instalados no Departamento de fitotecnia da Universidade Federal de Viçosa, nomeados como UFV-MA, UFV-MA2 e UFV-MB, respectivamente. Os outros dois experimentos (um de mancha-angular e um de mofo-branco) foram instalados na Fazenda Experimental Vale do Piranga (EPAMIG) em Oratórios, MG, nomeados como FEVP-MA e FEVP-MB, respectivamente. Nos experimentos de MA, as cultivares de feijão utilizadas foram Ouro-Vermelho (grupo comercial vermelho) em UFV-MA e Ouro Negro (grupo comercial preto) em UFV-MA2 e FEVP-MA. Nestes experimentos, as diferentes severidades da doença foram obtidas pela aplicação de fungicidas em doses variadas aos 45, 60 e 75 dias após emergência. Foi utilizado o delineamento de blocos casualizados com quatro tratamentos, sendo dez repetições em UFV-MA e FEVP-MA e oito em UFV-MA2. No FEVP-MB foram utilizados tratamentos arrançados no esquema fatorial 4x2x2: densidades de plantas (4, 7, 10 e 13 plantas.m<sup>-1</sup>), genótipos de feijão do grupo carioca (CNFC 10720 e VC 6) e tratamentos com fungicida (com ou sem aplicação), aplicado no início da floração e dez dias depois. O esquema fatorial foi utilizado como método para proporcionar diferentes níveis de severidade de doença. Medidas de reflectância hiperespectral foram obtidas por espectroradiômetro com resolução de 1 nm. A faixa útil de leitura adotada foi entre 440 e 900 nm. Imagens multiespectrais foram adquiridas por meio

de uma câmara de três CCDs e cinco faixas espectrais (azul, verde, vermelho, *red-edge* e infravermelho). Um painel *Spectralon* de quatro cores de reflectâncias conhecidas foi posicionado dentro do campo de visão da câmara multiespectral no momento da aquisição. Valores de pixel de cada cor do painel na imagem foram associados aos seus respectivos valores de reflectância utilizando métodos de regressão linear simples. Isto permitiu a transformação de números digitais para reflectância em cada imagem. A aquisição de reflectâncias hiperespectrais e de imagens multiespectrais sobre o dossel foram feitas de uma altura de três metros do solo, utilizando uma plataforma metálica de quatro rodados. Estas aquisições foram feitas sob condições de céu aberto, nos horários entre 10:00 e 14:00 horas (horário local de Brasília), de forma a minimizar a influência na geometria de iluminação. O intervalo entre as aquisições foi de sete dias e se iniciaram a partir do estágio fenológico V4 (terceira folha trifoliada completamente aberta). Para medidas de reflectâncias foliar, utilizou-se uma sonda de contato com fonte de luz própria, conectada ao espectrorradiômetro. Processos de calibração para medidas de reflectância hiperespectral foram feitos utilizando painel *Spectralon* branco. Severidade da doença dos experimentos de MA foram determinados pela interpretação de imagens referentes a 27 folhas extraídas dos experimentos nos dias de leitura de reflectância. A interpretação foi feita pelo método de função discriminante. A acurácia da interpretação foi feita pelo índice Kappa. As imagens das folhas foram obtidas por câmara fotográfica comercial em ambiente interno e em condição de iluminação controlada. A severidade do mofo-branco foi avaliada com base em interpretação visual por pesquisador experimentado nesta atividade, durante o estágio fenológico R9. Utilizou-se a regressão por Mínimos Quadrados Parciais (PLS) para definição do conjunto de comprimentos de onda que melhor estime a severidade da doença numa determinada data. Para uso desse método, as observações foram previamente divididas em dois subgrupos: o primeiro (calibração) foi utilizado para construção do modelo e o segundo subgrupo para testar o modelo definido. Medidas de Raiz do Erro Médio Quadrado (RMSE) e de correlação entre valores medidos e preditos da severidade da doença foram utilizadas para avaliar os modelos. Antes do uso da regressão PLS, as observações foram submetidas à estatística Z, utilizando método robusto, para a identificação de variáveis anômalas. Nos experimentos de MA foram executados métodos de correlações entre cada

comprimento de onda hiperespectral e o índice de severidade de doença correspondente, como método alternativo à regressão PLS para determinar os comprimentos de onda que melhor predizem os efeitos da doença. Foram então identificados os comprimentos de onda que proporcionaram significância estatística quando correlacionados à severidade da doença. Medidas de reflectância e índices de vegetação provenientes de reflectâncias hiper- e multiespectral do dossel foram utilizados nos experimentos de MB. Foram utilizados os índices de vegetação DVI, GNDVI, MCARI, MCARI2, MSAVI, NDVI, OSAVI, RDVI, TCARI e a razão entre índices, MCARI/OSAVI e TCARI/OSAVI. Os resultados em todos os experimentos indicaram que as mudanças na resposta espectral, relacionados com a severidade da doença, são dependentes dos comprimentos de onda. Os modelos por regressão PLS e os índices de vegetação com base em medidas hiperespectrais apresentaram melhor desempenho para identificação das doenças do que os modelos obtidos de medidas multiespectrais. O uso de índices de vegetação da família CARI (TCARI e MCARI) e sua razão com OSAVI, bem como, de DVI, foram os mais representativos para identificação de MB. Alterações no comportamento espectral da mancha-angular demonstraram ser mais expressivas nos estádios fenológicos finais da cultura, mais especificamente em R8 e R9. As faixas espectrais de maior representatividade, considerando mancha-angular e mofo-branco, foram o vermelho, *red-edge* e o infravermelho. As faixas espectrais de transição entre as bandas azul e verde e entre as bandas verde e vermelho também mostraram-se sensíveis à estimativa de mancha-angular e mofo-branco para reflectâncias foliar.

## ABSTRACT

MACHADO, Marley Lamounier, D.Sc., Universidade Federal de Viçosa, November of 2013. **Bean diseases detection by spectral characteristics.** Advisor: Francisco de Assis de Carvalho Pinto. Co-advisors: Daniel Marçal de Queiroz and Trazilbo José de Paula Júnior.

This work aims to test the hypothesis that it is possible to detect the presence of fungal diseases of bean plants, typical of periods of fall/winter, using leaf reflectance and canopy. For this, it was done the analysis of plant the spectral behavior of the disease on several dates of the crop cycle, the development build predictive mathematical models for multivariate methods, the testing existing models (Vegetation Index) and the determination of the wavelengths most representatives to estimate the disease severity. Five experiments were deployed in locations with a history of angular leaf spot (MA) and white mold (MB). Two experiments of angular leaf spot and one of white mold were installed at the Department of Crop Science at the Federal University of Viçosa, UFV - named as UFV-MA, UFV-MA2 and UFV-MB, respectively. The other two experiments (one of angular leaf spot and one of white mold) were installed at the Experimental Farm Vale do Piranga (EPAMIG) in Oratorios, MG, named as FEVP-MA and FEVP-MA, respectively. In the experiments of MA, the bean cultivars used were Ouro Vermelho (red trade group) at UFV-MA and Ouro Negro (black trade group) at UFV-MA2 and FEVP-MA. In these experiments, the different disease severities were obtained by applying different varied fungicides doses at 45, 60 and 75 days after plant emergence. A randomized complete block design with four treatments was used, with ten replications on UFV-MA and FEVP-MA and eight replications on UFV-MA2. On FEVP-MB the treatments were arranged in a 4x2x2 factorial arrangement: plant densities (4, 7, 10 and 13 plants.m<sup>-1</sup>), bean genotypes of the carioca group (CNFC 10720 and CV 6) and fungicide treatments (with or no application), applied at the beginning of flowering and ten days later. The factorial arrangement was used as a method for providing different levels of disease severity. Hyperspectral reflectance measurements were obtained by spectroradiometer with a resolution of 1 nm. The useful reading was between 440 and 900 nm. Multispectral images were acquired by a three CCD camera and five spectral bands (blue, green, red, red-edge and infrared).

A Spectralon panel of four colors of known reflectance was positioned within the multispectral camera field of view at the time of acquisition. Pixel values of each panel color in the image were associated with their respective reflectance values using simple linear regression methods. This allowed the transformation of digital numbers for reflectance in each image. The acquisition of hyperspectral reflectances and multispectral images over the canopy were made from a height of three meters from the ground, using a four-wheeled metal platform. These acquisitions were made under clear sky conditions, at times between 10:00am and 2:00pm local time (GMT-Brasilia), in order to minimize the influence of the illumination geometry. The interval between acquisitions was seven days and it started from the V4 phenological stage (third completely open trifoliate leaf). For measurements of leaf reflectance, we used a contact probe with its own light source, connected to the spectroradiometer. Calibration processes for hyperspectral reflectance measurements were made using white Spectralon panel. The disease severity of MA experiments was determined by interpretation of 27 leaf images collected from the experiments on reading reflectance days. The interpretation was made by the discriminant function method. The interpretation accuracy was made by the Kappa index score. The leaves images were grabbed indoors by commercial camera with controlled illumination. The severity of white mold was evaluated based on visual interpretation by an experienced researcher in this activity, during the phenological stage R9. A regression by Partial Least Squares (PLS) was used for the set of wavelengths that best estimate the severity of the disease at a certain date. To use this method, the observations were previously divided into two sub-groups: the first (calibration) was used for the model construction and the second subgroup for testing the model. Root Mean Square Error (RMSE) and correlation between measured and predicted values of disease severity were used to evaluate the models. Before using PLS regression, observations were subjected to statistic Z using robust method for identifying anomalous variables. Methods of correlations were executed between each hyperspectral wavelength and the corresponding disease severity index, as an alternative method to the PLS regression to determine the wavelengths that best predict the effects of the disease. The wavelengths that presented significant correlation with disease severity were identified. Reflectance measurements and vegetation indices derived from hyper and multispectral reflectance of the canopy

were used in the experiments of MB. Vegetation indices DVI, GNDVI, MCARI, MCARI2, MSAVI, NDVI, OSAVI, RDVI, TCARI and ratio indices, MCARI / OSAVI and TCARI / OSAVI were used. The results in all experiments indicated that changes in the spectral response, related to the disease severity, were dependent on the wavelength. PLS regression models and vegetation indices based on hyperspectral measurements presented better performance for identification of diseases than the models based on from multispectral measurements. The use of vegetation indices of CARI (TCARI and MCARI) family and its ratio with OSAVI, as well with DVI, were the most representative in identifying MB. Alterations in the spectral behavior of angular leaf spot proved to be more expressive in the final plant growing stages, more specifically in R8 and R9. The spectral bands of greater representativeness were red, red-edge and infrared. The transition spectral ranges between blue and green bands and between green and red bands were also sensitive to the estimate of angular leaf spot and white mold for leaf reflectance.

## INTRODUÇÃO GERAL

O feijão comum (*Phaseolus vulgaris.*) é a leguminosa mais importante para o consumo humano, pois proporciona uma importante fonte de proteína ( $\cong 22\%$ ), vitaminas (ácido fólico) e minerais (Ca, Cu, Fe, Mg, Mn, Zn) (BEEBE, 2012). O Brasil é o maior produtor de feijão do mundo respondendo por 3,5 milhões de toneladas de grãos, área de produção de 4,01 milhões de hectares e com rendimento médio no país de  $939 \text{ kg.ha}^{-1}$ , considerando a safra de 2010 (BRAIR et al., 2013). Minas Gerais é o segundo maior estado produtor (CONAB, 2013), com produção de 663,7 e 564,8 mil toneladas nas safras de 2011/2012 e 2012/2013, respectivamente, o que representa 23% e 20% da produção nacional. Além da relevância na dieta do brasileiro, o feijão é um dos produtos agrícolas de maior importância econômica-social. MAPA (2013) informa que de cada dez brasileiros, sete consomem feijão diariamente, sendo que a produção nacional é praticamente direcionada ao mercado interno, onde apenas uma pequena parte é exportada.

A maior parte da produção brasileira de feijão era proveniente do cultivo das *águas* e da *seca*, ambos com elevado risco. No primeiro caso, por coincidir a colheita com período chuvoso, e, no segundo, por ser uma época em que as chuvas são bastante escassas, podendo ocorrer deficiência hídrica nas fases críticas da cultura, isto é, floração, formação das vagens e enchimento dos grãos. A possibilidade de cultivar o feijão em uma terceira e quarta época de plantio, outono-inverno e inverno-primavera, com o uso da irrigação, em regiões de inverno ameno, despertou o interesse de grandes agricultores de Minas Gerais (BORÉM e CARNEIRO, 2006).

A condição de alta umidade proporcionada pela irrigação e temperaturas amenas no meio do ano favorece o desenvolvimento de diversas doenças fúngicas nos plantios de feijão. PAULA JUNIOR e WENDLAND (2012) mencionam que vários fungos, bactérias, vírus ou nematoides podem causar podridões no sistema radicular e no caule, colonizar o sistema vascular das plantas, incidir sobre a parte aérea e, em condições ambientais propícias, contribuir para reduzir a produtividade da cultura.

No estudo sobre ambiente e doenças fúngicas para plantas, CANTERI et al. (2010) informam que entre os fatores edafoclimáticos, a umidade e a temperatura são as que mais influenciam o desenvolvimento das doenças. A umidade é o fator determinante para a ocorrência de doenças em plantas, principalmente as doenças

foliares. A temperatura age como um catalisador, ou seja, acelera ou retarda o ciclo do patógeno.

O mofo-branco [*Sclerotinia sclerotiorum* (Lib.) de Bary] e a mancha-angular, causada por *Pseudocercospora griseola* (Sacc.) são doenças que podem causar sérios danos à cultura nos períodos de outono / inverno. O mofo-branco, segundo PAULA JÚNIOR et al. (2012), é a doença do feijoeiro mais destrutiva nas áreas irrigadas do Brasil, notadamente nos plantios realizados nas safras de outono-inverno. A baixa evaporação observada nessa época e a alta umidade do solo proporcionada pela irrigação também contribuem para favorecer o desenvolvimento da doença. A mancha-angular é a principal doença da parte aérea, causando sérios prejuízos, especialmente de abril a julho, quando são observados, nas principais regiões produtoras, temperaturas amenas e orvalho (PAULA JUNIOR e ZAMBOLIM, 2006). Além disso, quando se utiliza irrigação por aspersão, a umidade favorece essa doença (PAULA JUNIOR e ZAMBOLIM, 2006). A mancha-angular ocorre com maior frequência a partir do florescimento, atingindo níveis críticos durante o estágio de formação e maturação de vagens (MODA-CIRINO et al, 2012).

O impacto de doenças de plantas sobre a fisiologia e fenologia das plantas podem causar modificações em pigmentos foliares. Essas modificações podem influenciar na absorção da radiação eletromagnética em função da fotossíntese, dado a utilização desta energia pelos pigmentos fotossintetizantes como a clorofila, xantofila e caroteno. Além das mudanças na pigmentação das folhas, plantas doentes podem apresentar danos como o enrugamento da folha, murcha, atrofia, clorose, necrose ou abscisão de partes da planta. No caso de ocorrência de danos às folhas, poderá ocorrer alterações nas respostas espectrais da planta visto que a folha tem como função principal viabilizar a interação com a radiação eletromagnética na região do visível (PONZONI e SHIMABUKURO, 2009). Assim, fatores ambientais ou de caráter patogênico que atuem na composição química ou estrutural das folhas vão acarretar modificações nas suas propriedades espectrais.

A intensidade das doenças de planta pode ser avaliada através do sensoriamento remoto que se baseia na medição da energia refletida ou emitida por um objeto sem contato físico com o mesmo. Assim, medidas de reflectância espectral podem ser utilizadas para a avaliação não-destrutiva do estado fisiológico da vegetação e detectar o impacto do estresse causado por doenças de plantas e deficiências

nutricionais (BLACKBURN, 2007), em que, reflectância corresponde a quantidade da radiação refletida pelo objeto pela quantidade de radiação que incide nele. ZHANG (2011) menciona que a detecção de doenças de plantas usando sensoriamento remoto depende dos dados iniciais que ligam respostas espectrais à gravidade da doença. Assim, a identificação de assinatura espectral para a doença é o primeiro passo na aplicação dessas tecnologias para melhorar o monitoramento e controle da doença. MAHLEIN (2012) menciona que cada doença influencia a reflectância do tecido foliar de uma forma única resultando em assinaturas espectrais específicas para cada doença. Assinatura espectral corresponde à intensidade relativa com que cada corpo reflete ou emite a radiação eletromagnética nos diversos comprimentos de onda.

O uso de sensores terrestres apresentam vantagens em relação aos instalados em satélites ou aeronaves, tais como obtenção instantânea da informação e a não necessidade de processamento de imagem. Portanto, uma metodologia que combina dados radiométricos com diferentes tipos de sensores instalados em plataforma terrestres, pode ser usada no sentido de se estabelecer métodos rápidos e de baixo custo que viabilizem a identificação de áreas afetadas por doenças. Esses métodos permitiriam a aplicação de fungicidas a taxas variadas nos locais e períodos adequados, visto que, segundo PAULA JUNIOR e ZAMBOLIM (2006), o controle químico de doenças de feijão geralmente é feito em toda lavoura de forma preventiva. MOSHOU (2004) acrescenta que a pulverização uniforme não só apresenta custo elevado, mas também aumenta a probabilidade de contaminação das águas subterrâneas e de resíduos tóxicos nos produtos agrícolas. Para as aplicações de fungicidas em locais específicos, a dinâmica espaço-temporal de doenças das culturas deve ser bem conhecida. Assim o sensoriamento remoto pode ser uma ferramenta útil para monitorar a heterogeneidade do vigor vegetativo em culturas agrícolas.

Medidas ópticas de reflectância e índices espectrais adequados oferecem diversas vantagens sobre metodologias convencionais de avaliação visual. Isto inclui a utilização de bandas de frequência que vão além do limite de sensibilidade humana, proporcionando a capacidade de detectar os primeiros sintomas da doença, caso os sintomas pré-visuais existam (HUANG et al., 2007). Normalmente, no momento em que a doença se torna visível, esta poderá estar em um estágio avançado de

propagação, reduzindo as chances do produtor em mitigar os danos a custos financeiros aceitáveis. Para determinar com antecedência o grau de severidade da doença, haveria a necessidade do produtor enviar amostras para um laboratório e empregar métodos de detecção convencionais, o que torna o processo caro e demorado. Um sistema de detecção precoce da doença por sensores remotos pode auxiliar na redução das perdas causadas por doenças das plantas, podendo evitar ainda mais a sua propagação. Informação precoce sobre a saúde da cultura e detecção da doença pode facilitar o controle de doenças por meio de estratégias de gestão adequadas, como controle através de aplicações de pesticidas e fungicidas, podendo assim melhorar a produtividade (SANKARAN et al., 2010).

Diversos estudos têm demonstrado que folhas ou dossel de culturas infectadas com doenças fúngicas sofrem alterações significativas na faixa espectral do visível e do infravermelho, onde, a ocorrência de necrose ou clorose aumenta a reflectância na faixa do visível, especialmente em comprimentos de onda que ocorrem absorção de clorofila. Por outro lado, as reflectâncias são menores na região do infravermelho, no entanto, mais sensível à influência da doença (CAO et al., 2013; YANG, 2010; PONZONI e SHIMABUKURO, 2009; FRANKE e MENZ, 2007). Portanto, é importante a identificação dos comprimentos de onda mais representativos para a caracterização da doença, sendo que, estes valores podem ser utilizados individualmente ou em modelos matemáticos para quantificar os níveis de severidade de doença. MAHLEIN (2010) menciona a necessidade de implementar técnicas apropriadas para caracterizar a fonte principal da variabilidade espectral e identificar comprimentos de onda que oferecem o máximo conteúdo de informação dos dados de reflectância. Em levantamentos hiperespectrais, as medidas de reflectâncias apresentam uma característica que é a alta correlação entre duas (colinearidade) ou mais variáveis (multicolinearidade). Assim, há a possibilidade de redução no número de comprimentos de onda, sem perda significativa de informação e sem sacrificar a capacidade de caracterização da cultura (SONG et al., 2011). Alguns trabalhos apresentaram os comprimentos de onda mais significativos para a identificação de doenças, tais como, PRABHAKAR et al. (2013), estudando o mosaico amarelo em Feijão; ZHANG (2011) estudando a identificação das doenças de arroz; JONES et al. (2010), estudando a severidade de mancha bacteriana em tomate; e, MALTHUS e

MADEIRA (1993), estudando folhas de feijão infectadas com o fungo *Botrytisfabae* (mancha de chocolate).

Neste sentido, alguns autores têm apresentado diferentes métodos de seleção de comprimento de onda com base de levantamentos espectrométricos em áreas agrícolas, tais como: 1) análise da correlação entre comprimentos de onda para destacar aqueles mais representativos, dado a redundância entre eles (SONG et al., 2011; JAIN et al., 2007); 2) análise de componentes principais (PCA), para redução da quantidade de comprimentos de onda hiperespectrais para poucos componentes que explicam a maior parte da variabilidade (SONG et al., 2011; JAIN et al., 2007); 3) regressão linear múltipla (MLR) para a estimativa dos índices de severidade de doença (CAO et al., 2013; JONES et al., 2010; YANG, 2010). Quando o número de observações são poucos, não são significativamente redundantes e tem um relacionamento bem compreendido com a variável resposta, o uso de MLR pode ser uma boa maneira de seleção de comprimentos de onda. No entanto, FERREIRA (1999) menciona que método MLR sofre do problema de colinearidade: o número de amostras deve exceder o número de variáveis, que, por sua vez, devem fornecer predominantemente informação única. Tem-se nesse caso a opção de selecionar um certo número de variáveis que seja menor que o número de amostras e que produzam informação "única", o que pode ser demorado e tedioso. Como alternativa à MLR, a regressão por Mínimos Quadrados Parciais (PLS) é capaz de lidar com um grande número de variáveis respostas altamente correlacionados (indicadores ou descritores) e com pequenos conjuntos de observações (TEÓFILO et al., 2009). A base para construção de modelos por regressão PLS é a PCA, em que os dados originais X e Y são decompostos em matriz de *scores* e *loadings*. *Score* é a coordenada de cada objeto ao longo de um eixo (componente principal). *Loading* é a participação de cada medida em um eixo, ou quanto cada variável antiga contribui. A função dos componentes principais é descrever a variação ou espalhamento entre os pontos usando o menor número possível de eixos.

Comprimentos de onda específicos podem também ser combinados em duas ou mais unidades, de forma a destacar uma propriedade particular de vegetação. Esta relação matemática compõe o chamado índice de vegetação, e destina-se também a minimizar efeitos tais como a irradiância solar, efeitos de fundo do solo e de efeitos atmosféricos (EPIPHANIO et al., 1996). Índices vegetativos têm sido desenvolvidos

para compreender variáveis do dossel e para servir de base em muitas aplicações de sensores remotos para manejo, visto que estão correlacionados com várias propriedades biofísicas importantes (AHAMED et al., 2011). Muitos índices têm sido propostos na literatura com o objetivo de explorar as propriedades espectrais da vegetação, especialmente nas faixas do visível e infravermelho próximo. Esses índices são relacionados a parâmetros, como cobertura vegetal, biomassa e índice de área foliar (PONZONI e SHIMABUKURO, 2009). Segundo MAHLEIN et al. (2010), índices de vegetação podem ainda ser úteis na diferenciação entre plantas doentes e saudáveis; e também na quantificação de doenças.

O presente trabalho pretende testar a hipótese de que é possível detectar a presença de doenças fúngicas de feijoeiros em períodos de outono/inverno a partir do estágio fenológico V4. Para tal, será obtido medidas de reflectância de folhas e de dossel feitas com periodicidade de sete dias em experimentos implantados em campo, utilizando plataforma terrestre com câmara multiespectral e espectroradiômetro com sonda de contato acoplado. Pretende-se usar de ações como: analisar o comportamento espectral das doenças em diversas datas do ciclo da cultura, construir modelos matemáticos preditivos por métodos multivariados, testar modelos existentes (índices de vegetação) e determinar os comprimentos de onda mais representativos para a estimativa da severidade da doença. Uma vez comprovada esta hipótese, cria-se a expectativa de construção de sensores e de plataformas de visão artificial para uso em equipamento de mão e em máquinas agrícolas, promovendo assim, o controle localizado em lavouras de feijão com fungicidas ou com tratamentos culturais que o produtor julgar necessário.

Esta Tese foi estruturada em três capítulos, compreendendo as doenças de mancha-angular e mofo-branco para feijão. A mancha-angular foi estudada no capítulo 1 utilizando reflectância hiperspectral foliar e de dossel. O capítulo 2 estudou o mofo-branco utilizando reflectâncias hiper- e multiespectral sobre dossel. O capítulo 3 estudou o mofo-branco utilizando reflectância hiperspectral foliar.

## BIBLIOGRAFIA GERAL

AHAMED, T.; TIAN, L.; ZHANG, Y.; TING, K. C. A review of remote sensing methods for biomass feedstock production. **Biomass and Bioenergy**, v. 35, n. 7, p. 2455–2469, 2011.

BEEBE, S. E. Common bean breeding in the tropics. In: Janick, J. (Eds.) **Plant breeding reviews**. New Jersey: Wiley-Blackwell. 2012. v. 36, p. 357-426.

BLACKBURN, G. A. Hyperspectral remote sensing of plant pigments. **Journal of Experimental Botany**, v.58, p.844-867, 2007.

BLAIR, M. W.; BRONDANI, R. V. P.; DÍAZ, L. M.; PELOSO, M. J. DEL. Diversity and Population Structure of Common Bean from Brazil. **Crop Science**, v. 53, p. 1983–1993, 2013.

BORÉM, A.; CARNEIRO, J. E. S. A cultura. In: VIEIRA, C.; PAULA JÚNIOR, T.J.; BORÉM, A. (Ed.). **Feijão**. 2ª edição atualizada. Viçosa: UFV, 2006. p.13-18.

CANTERI, M. G.; SILVA, O. C. da; TSUKAHARA, R, Y. In: Pria, M. D.; Silva, O. C. (Ed.). **Cultura do Feijão: doenças e controle**. Ponta Grossa: UEPG, 2010. p.133-148.

CAO, X.; LUO, Y.; ZHOU, Y.; DUAN, X.; CHENG, D. Detection of powdery mildew in two winter wheat cultivars using canopy hyperspectral reflectance. **Crop Protection**, v. 45, p. 124-131, 2013.

CONAB. **Acompanhamento da Safra Brasileira. Grãos: Safra 2012/2013**. Disponível em: <[http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13\\_07\\_09\\_09\\_04\\_53\\_boletim\\_graos\\_junho\\_\\_2013.pdf](http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13_07_09_09_04_53_boletim_graos_junho__2013.pdf)>. Acesso em 21/10/2013.

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

FERREIRA, M. M. C.; ANTUNES, A. M.; MELGO, M. S.; VOLPE, P. L. O. **Química Nova**. Quimiometria I: calibração multivariada , um tutorial. , p. 1–14, 1999.

FRANKE, J.; MENZ, G. Multi-temporal wheat disease detection by multi-spectral remote sensing. **Precision Agriculture**, v. 8, n. 3, p. 161-172, 2007.

HUANG, W.; LAMB, D. W.; NIU, Z.; et al. Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging. **Precision Agriculture**, v. 8, n. 4-5, p. 187–197, 2007.

JAIN, N.; SHANKAR, Æ. S.; SINGH, R. Æ. J. P.; PANIGRAHY, Æ. 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.

JONES, C. D.; JONES, J. B.; LEE, W. S. Diagnosis of bacterial spot of tomato using spectral signatures. **Computers and Electronics in Agriculture**, v. 74, n. 2, p. 329-335, 2010.

MAHLEIN, A. K. et al. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. **Precision Agriculture**, v. 11, n. 4, p. 413-431, 2010.

MAHLEIN, A.-K.; STEINER, U.; HILLNHÜTTER, C.; DEHNE, H.-W.; OERKE, E.-C. Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases. **Plant methods**, v. 8, n. 1, p. 3, 2012.

MALTHUS, T. J.; MADEIRA, A. C. High Resolution Spectroradiometry : Spectral Reflectance of Field Bean Leaves Infected by *Botrytis fabae*. **Remote Sensing of Environment**, n. 45, p. 107-116, 1993.

MAPA. **Vegetal: Feijão.** Disponível em: <<http://www.agricultura.gov.br/vegetal/culturas/feijao>>. Acesso em 21/10/2013.

MODA-CIRINO, V.; RAMALHO, M. A. P.; ABREU, A. F. B. [et al.]. Mancha-angular. In: PAULA JÚNIOR e WENDLAND (Eds) **Melhoramento genético do feijoeiro-comum e prevenção de doenças**. Viçosa, MG: EPAMIG Zona da Mata. 2012. Cap. 4, p. 71-81.

MOSHOU, D.; BRAVO, C.; WEST, J.; et al. Automatic detection of “yellow rust” in wheat using reflectance measurements and neural networks. **Computers and Electronics in Agriculture**, v. 44, n. 3, p. 173–188, 2004.

PAULA JÚNIOR, T. J.; WENDLAND A. **Melhoramento genético do feijoeiro-comum e prevenção de doenças**. Viçosa, MG: EPAMIG Zona da Mata, 2012. 157p.

PAULA JÚNIOR, T. J.; ZAMBOLIM, L. Doenças. In: VIEIRA, C., PAULA JÚNIOR, T.J. & BORÉM, A. (Eds.) **Feijão: Aspectos gerais e cultura no Estado de Minas**. Viçosa: Editora UFV. 2006. p. 375-433.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São Jose dos Campos, SP: Ed. A.Silva Vieira, 2009. 135p.

PRABHAKAR, M.; PRASAD, Y. G.; DESAI, S. et al. Hyperspectral remote sensing of yellow mosaic severity and associated pigment losses in *Vigna mungo* using multinomial logistic regression models. **Crop Protection**, v. 45, p. 132-140, 2013.

SANKARAN, S.; MISHRA, A.; EHSANI, R.; DAVIS, C. A review of advanced techniques for detecting plant diseases. **Computers and Electronics in Agriculture**, v. 72, n. 1, p. 1–13, 2010.

SONG, S. et al. Wavelength selection and spectral discrimination for paddy rice , with laboratory measurements of hyperspectral leaf reflectance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 5, p. 672-682, 2011.

TEÓFILO, R. F.; MARTINS, J. P. A.; FERREIRA, M. M. C. Sorting variables by using informative vectors as a strategy for feature selection in multivariate regression. **Journal of Chemometrics**, v. 23, n. 1, p. 32-48, 2009.

YANG, C. M.. Assessment of the severity of bacterial leaf blight in rice using canopy hyperspectral reflectance. **Precision Agriculture**, v.11, p.61-81, 2010.

ZHANG, H.; HU, H.; ZHANG, X. et al. Estimation of rice neck blasts severity using spectral reflectance based on BP-neural network. **Acta Physiologiae Plantarum**, v. 33, n. 6, p. 2461-2466, 2011.

### AVALIAÇÃO DE MANCHA-ANGULAR DE FEIJÃO UTILIZANDO REFLECTÂNCIA HIPERSPECTRAL FOLIAR E DE DOSSEL

### EVALUATION OF ANGULAR LEAF SPOT OF COMMON BEAN USING LEAF AND CANOPY HIPERSPECTRAL REFLECTANCE

#### RESUMO

Este estudo objetivou detectar a presença da mancha-angular utilizando reflectâncias hiperspectrais foliar e de dossel, e, determinar e comparar as alterações das respostas espectrais da planta provocadas pela doença em dossel e em folhas do feijoeiro. Foram utilizadas medidas hiperspectrais para identificar a assinatura espectral da planta infectada, os comprimentos de onda e modelos matemáticos mais representativos para a quantificação da doença. Foram conduzidos dois experimentos no município de Viçosa e um em Oratórios / MG, sob regime irrigado. As medidas de reflectâncias foram obtidas utilizando espectrorradiômetro com faixa espectral útil de leitura de 400 a 900 nm. Níveis de severidade da doença foram determinados com base na quantificação da área necrosada, utilizando imagens de folhas. A mancha-angular apresentou valores moderados de severidade. Os resultados indicam que as mudanças na resposta espectral na folha e no dossel do feijoeiro foram influenciadas pela severidade de mancha-angular. As faixas espectrais do vermelho e intervalo entre o *red-edge* e o infravermelho, segundo bandas espectrais do satélite RapidEye, mostraram-se como as mais sensíveis à presença da mancha-angular. A metodologia utilizada permitiu a discriminação dos comprimentos de onda para estimar a severidade da mancha-angular em diferentes estádios fenológicos.

**Palavras Chave:** Regressão PLS, Comprimento de onda, Assinatura espectral, *Pseudocercospora griseola* (Sacc. Ferr).

## ABSTRACT

This study aimed to detect the presence of angular leaf spot using hyperspectral leaf and canopy reflectance, and, to determine and to compare crop spectral response changes caused by angular disease in canopy and in plant leaves of common bean. It was utilized hyperspectral measurements to identify the spectral signature of the infected plant, the most representative wavelengths and mathematical models to quantify the disease. Two experiments were conducted in Viçosa and one in Oratorios / MG under irrigated condition. The reflectance measurements were obtained using a spectroradiometer with useful spectral range from 400 to 900 nm. Levels of disease severity were determined based on the quantification of the necrotic area, using leaf images. The angular leaf spot had moderate severity values. The results indicate that the changes in the spectral response in the leaf and in the canopy of the bean plant were influenced by the severity of angular leaf spot. The red and range between the infrared and the red-edge bands, according spectral bands of the RapidEye Satellite, showed to be the most sensitive to the presence of angular leaf spot. The methodology utilized allowed to discriminate the wavelengths for estimating the severity of angular leaf spot in different phenological stages.

**Keywords:** PLS Regression, Wavelength, Spectral Signature, *Pseudocercospora griseola* (Sacc. Ferr).

## INTRODUÇÃO

O feijão comum (*Phaseolus vulgaris*.) é a leguminosa mais importante para o consumo humano, pois proporciona uma importante fonte de proteína ( $\cong 22\%$ ), vitaminas (ácido fólico) e minerais (Ca, Cu, Fe, Mg, Mn, Zn) (BEEBE, 2012). Além da relevância na dieta do ser humano, o feijão é um dos produtos agrícolas de maior importância econômica-social no Brasil. MAPA (2013) informa que de cada dez brasileiros, sete consomem feijão diariamente. Pode ser cultivado tanto por grandes com pequenos produtores, bem como, ser produzido em diversas regiões do território brasileiro. No entanto, doenças da cultura pode ser um fator limitante da produção. A

mancha-angular [*Pseudocercospora griseola* (Sacc. Ferr)] tem sido apontada como a principal doença da parte aérea dos feijoeiros. Ela causa sérios prejuízos, especialmente no período de abril a julho, em regiões produtoras que apresentam condições climáticas de temperaturas amenas e que fazem uso de irrigação por aspersão, o que propicia condição de umidade favorável (PAULA JUNIOR e ZAMBOLIM, 2006). A mancha-angular ocorre com maior frequência a partir do florescimento, atingindo níveis críticos durante o estágio de formação e maturação de vagens (MODA-CIRINO et al., 2012).

O impacto de doenças de plantas sobre a fisiologia e fenologia das plantas varia com a interação patógeno-hospedeiro e pode causar modificações em pigmentos, enrugamento da folha, murcha, atrofia, clorose, necrose ou abscisão de partes da planta (PRABHAKAR et al., 2013). A intensidade das doenças pode, então, ser avaliada através da aplicação de ferramentas de sensoriamento remoto as quais se baseiam na medição da energia refletida ou emitida por um objeto sem que haja contato físico com o mesmo. Neste caso, as medidas de reflectância podem ser utilizadas para avaliação não-destrutiva do estado fisiológico da vegetação e para detectar o impacto do estresse causado por doenças de plantas e deficiências nutricionais (BLACKBURN, 2007).

Deteção de doenças de plantas usando sensoriamento remoto depende dos dados iniciais que ligam respostas espectrais à gravidade da doença. Assim, a identificação de assinatura espectral da planta é o primeiro passo na aplicação dessas tecnologias para melhorar o monitoramento e controle da doença (ZHANG, 2011). Assinatura espectral corresponde à intensidade relativa com que cada corpo reflete ou emite a radiação eletromagnética nos diversos comprimentos de onda. Diversos estudos têm demonstrado que folhas e dossel de culturas infectadas com doenças fúngicas sofrem alterações significativas na faixa do visível e do infravermelho (MAHLEIN et al., 2013; PRABHAKAR et al., 2013; CAO et al., 2013; YANG, 2010; PONZONI e SHIMABUKURO, 2009; FRANKE e MENZ, 2007).

Na assinatura espectral são identificados os comprimentos de onda mais representativos para a caracterização da doença. Esses comprimentos de onda podem ser utilizados individualmente, ou em modelos matemáticos, para quantificar os níveis de severidade de doença instalada. Assim, há a possibilidade de redução no número de comprimentos de onda, sem perda significativa de informação e sem

sacrificar a capacidade de caracterização da cultura (SONG et al., 2011). Neste sentido, alguns autores têm apresentado diferentes métodos de seleção de comprimentos de onda com base em levantamentos espectrométricos em áreas agrícolas, tais como: 1) Análise da correlação entre comprimentos de onda e variável dependente (SONG et al., 2011); 2) Análise de componentes principais – PCA, (SONG et al., 2011); 3) Regressão linear múltipla (CAO et al., 2013; JONES et al., 2010; YANG, 2010). 4) Regressão por Mínimos Quadrados Parciais (PLS). Entre as técnicas multivariadas a regressão PLS é capaz de lidar com variáveis respostas altamente correlacionadas (indicadores ou descritores) e com pequenos conjuntos de observações (TEÓFILO et al., 2009).

Entre os trabalhos pesquisados na literatura, não foi encontrada uma abordagem que identifique alterações espectrais do feijoeiro infectado com doenças fúngicas e que estime os níveis de severidade da doença por técnicas multivariadas. Portanto, este estudo pretende testar a hipótese de que é possível detectar a presença da mancha-angular utilizando reflectâncias hiperespectrais foliar e de dossel. Comprovada esta hipótese, pretende-se determinar e comparar as alterações espectrais provocadas pela mancha-angular em dossel e em folhas de feijoeiro. E também, identificar os comprimentos de onda e faixas espectrais que melhor estimem a severidade da doença em diversos estádios fenológicos.

## **MATERIAL E MÉTODOS**

### **Condução dos experimentos**

Foram conduzidos três experimentos em duas áreas de instalação: 1) Campo experimental Diogo Alves de Melo (UFV), situadas no campo experimental Diogo Alves de Melo (UFV), em Viçosa, MG, com coordenadas geográficas de 20°45'S e 42°52'W, altitude de 648 m; 2) Fazenda Experimental Vale do Piranga (FEVP)/EPAMIG, Oratórios, MG, com coordenadas de 20°24'S e 42°48'W, altitude de 450 m. As datas de plantio dos experimentos instalados na UFV foram 08/04 e 29/07/2011, enquanto que a instalação do experimento em Oratórios ocorreu em 26/07/2011. Estes experimentos serão daqui por diante designados como UFV, UFV-

1 e FEVP. Na Tabela 1 são apresentadas as épocas de coleta de dados para reflectância de dossel, reflectância foliar e fotografias de folhas. Estas fotografias foram utilizadas para determinar a área foliar necrosada pela mancha-angular. Medidas ausentes em qualquer data ocorreram por causa da presença de chuva ou de irrigação no dia de leitura ou de dia nublado (leituras de dossel).

**Tabela 1-** Épocas de coleta de dados de reflectância e de determinação da área foliar necrosada.

UFV					FEVP					UFV-2				
EF	DAE	RF	RD	AFN	EF	DAE	RF	RD	AFN	EF	DAE	RF	RD	AFN
V4	33	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	V4	21	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	R5	29	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
R5	40	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	R5	33	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	R5	37	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
R7	50	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	R6	41	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	R6	42	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
R8	57	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	R7	48	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	R7	50	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
R8	65	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	R8	55	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	R8	58	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>
R9	76	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	R8	63	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	R8	64	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
R9	84	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	R8	69	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	R9	72	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>
					R9	77	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	R9	79	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>

EF: estágio fenológico; DAE: dias após emergência; RF: reflectância foliar; RD: reflectância do dossel; AFN: área foliar necrosada; V(n°): fase vegetativa; R(n°): fase reprodutiva.

A cultura foi irrigada por aspersão convencional. O preparo do solo foi realizado por grade aradora. Para o controle de plantas invasoras, foram realizadas capinas manuais. Quando necessário, fizeram-se aplicações de inseticidas para o controle de pragas. Na adubação de plantio, foi empregada a fórmula comercial 8-28-16 de N-P<sub>2</sub>O<sub>5</sub>-K<sub>2</sub>O. Aos 20 dias após emergência (DAE) os feijoeiros receberam aplicação de solução de molibdênio na folhagem.

O delineamento utilizado foi o de blocos casualizados com quatro tratamentos. Dois experimentos tiveram 10 repetições (UFV e FEVP) e um teve 8 repetições (UFV-2). As parcelas experimentais foram constituídas de cinco fileiras de 5,5 m, espaçadas de 0,50 m. A área útil de cada parcela para tomada dos dados foi composta pelas três linhas centrais, eliminando-se 0,50 m de cada extremidade da linha. As densidades de semeadura foram de 10 sementes.m<sup>-1</sup>. O espaçamento entre parcelas foi de 1m de forma a permitir o trânsito de pessoas e equipamentos. Os locais de implantação do experimento foram contaminados com palhada de outros cultivos de feijoeiros infectados com a doença. A palhada foi distribuída uniformemente nas entrelinhas das parcelas, oito dias após a emergência. As diferentes intensidades da doença foram obtidas pela aplicação de fungicidas em doses variadas. Nos experimentos UFV-2 e FEVP utilizou-se o produto Cerconil (tiofanato Metílico+clorotafonil) aplicado aos 30, 45 e 60 DAE em doses de 0, 200, 600 e 1800 g.ha<sup>-1</sup>. No experimento UFV utilizou-se o fungicida Amistar (composto de azoxistrobina), aplicado aos 45, 60 e 75 DAE nas doses de 0, 50, 100 e 150 g.ha<sup>-1</sup>. Os fungicidas foram aplicados com pulverizador costal. A cultivar de feijão utilizada no experimento UFV foi a Ouro Vermelho, grupo comercial vermelho, suscetível à mancha-angular e ferrugem, mas resistente à antracnose. Nos experimentos UFV-2 e FEVP, utilizou-se o cultivar Ouro Negro, grupo comercial preto, suscetível à mancha-angular, porém, com resistência à ferrugem.

### **Aquisição de dados em campo**

As medidas de reflectâncias foram feitas sobre a folha e sobre o dossel do feijoeiro, usando estrutura própria. Utilizou-se o espectrorradiômetro ASD FieldSpec HandHeld2 (Analytic Spectral Devices, Boulder, EUA), com campo de visão do sensor óptico de 25°, faixa espectral entre 350-1100 nm. A faixa útil de leitura foi entre 400 e 900 nm, descartando os dados espectrais ruidosos nos extremos. Operações de otimização e calibração de reflectância (aquisição de referência de branco padrão) foram realizadas antes da tomada dos dados usando painel de referência branca “Spectralon” (Labsphere, North Sutton, USA). Cada ponto adquirido de reflectância correspondeu a uma média de 10 varreduras feita pelo sensor, referente ao mesmo alvo. O processamento das informações para cálculo das

reflectâncias foi feito com o software ViewSpecpro (Analytic Spectral Devices, Boulder, EUA).

Para medidas de reflectância em folhas, utilizou-se uma sonda de contato com fonte de luz própria tipo Halogênica, 6 watts de potência, com temperatura de cor de 2911+/-10 K. Os processos de calibração, com o painel “Spectralon”, foram feitos em intervalos de 10 a 20 minutos para medidas de reflectância. A lâmpada de halogênio foi pré-aquecida por 90 minutos antes das leituras visando aumentar a qualidade e homogeneidade dos dados espectrais (MANHALEN, 2010). O tempo de integração para conversão da luz recebida em acúmulo de sinal elétrico foi de 138ms. Nos experimentos, as reflectâncias foliares foram obtidas de 27 folhas extraídas em nove plantas. De cada planta, colheu-se uma folha do terço superior, uma do terço médio e uma do terço inferior. As leituras de reflectâncias dessas folhas foram feitas imediatamente após a extração. O valor da reflectância foliar da parcela foi definido com a média das 27 leituras.

Para aquisição dos dados de espectrometria do dossel foi utilizada uma plataforma metálica de quatro rodados de eixos articulados de forma a tornar variável o tamanho da bitola, para ajustar o equipamento a diferentes larguras de parcelas. Para medidas da reflectância do dossel, utilizou-se uma fibra óptica, extensão de 4 m, conectada ao espectraloradiômetro e a um suporte tipo pistola, posicionado a 3 metros do solo, direcionado a nadir. A aquisição das reflectâncias sobre dossel foi realizada semanalmente, entre 10:00 e 14:00 horas (horário local de Brasília), para minimizar a influência na geometria de iluminação (ângulos zenital solar e azimutal solar). Todas as medidas foram feitas com céu aberto. Calibrações utilizando o painel “Spectralon” foram feitos em intervalos de 10 a 20 minutos. Este intervalo visou diminuir o efeito de geometria do sol e de mudanças atmosféricas, como cobertura de nuvens, umidade ou vapor de água e mudanças significativas de temperatura. O tempo de integração para conversão da luz recebida em acúmulo de sinal elétrico foi de 276 ms para reflectância de dossel. Em função da altura de instalação do equipamento e do campo de visão do espectraloradiômetro, a medição compreendeu uma área circular de 1,33 metros de diâmetro sobre o solo. A leitura de reflectância da parcela foi definida com média de três leituras, desconsiderando a bordadura. Foram feitas duas leituras nos extremos da parcela e uma na parte central.

## Determinação dos níveis de doença

A severidade da mancha-angular, que corresponde à área foliar necrosada (AFN), foi determinada a partir de folhas extraídas para a obtenção da reflectância foliar. Essas folhas foram dispostas lado a lado no fundo de uma caixa de madeira de formato cúbico (0,80 x 0,80 x 0,80m) com o interior iluminado por seis lâmpadas fluorescentes de 20 watts. Utilizou-se uma câmara fotográfica comercial com disparador remoto, com objetiva posicionada de forma perpendicular às folhas. As imagens obtidas foram em formato RGB (Red, Green, Blue), com imagens de 8 bits por banda (0 a 255) e resolução de 3,78 pixel.mm<sup>-1</sup>. As imagens foram obtidas a partir do aparecimento dos primeiros sintomas da doença no experimento (estádios fenológicos R5 ou R6). As imagens (e as medidas de reflectância) foram feitas até o início do estágio R9 para evitar medidas de necrose por maturação. Para identificação da AFN por classificação das imagens, foram obtidas 50 amostras de cada classe presente na folha. Este número de amostras é recomendado por CONGALTON (1991) como o mínimo exigido. Em cada imagem foram identificados três tipos de feições na folha após surgimento da doença: verde (saudável), clorose e necrose. O AFN foi quantificado pelo percentual correspondente à área de pixels referentes à feição “necrose”. O processo de classificação foi executado sobre as imagens transformadas em quatro sistemas de cores, no caso, RGB, yCbCr, Lba e HSV (PEDRINI e SCHWARTZ, 2008). O modelo matemático utilizado para a classificação foi a função discriminante quadrática, derivado do teorema de Bayes, conforme Equação 1.

$$D_i(X) = \ln(p(W_i)) - \frac{1}{2} \ln|C_i| - \frac{1}{2} [(X - m_i)^T \cdot C_i^{-1} \cdot (X - m_i)] \quad (1)$$

em que,  $D_i(X)$ : função discriminante da classe ‘i’ do vetor aleatório  $X$ ;  $C_i$ : matriz de covariância da classe ‘i’;  $X$ : vetor aleatório de características;  $m_i$ : vetor de médias da classe ‘i’;  $p(W_i)$ : probabilidade de ocorrência da classe ‘i’.

Após estabelecidas as três classificações, o desempenho do classificador foi determinado pelo índice Kappa (COHEN, 1960), conforme Equação 2.

$$\hat{K} = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}{n^2 - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}} \quad (2)$$

em que,  $x_{ii}$ : elemento da matriz de confusão na linha  $i$  e coluna  $i$  (diagonal) da matriz de erros;  $x_{\oplus i}$ : somatório da linha  $i$ ;  $x_{i\oplus}$ : somatório da coluna  $i$ ;  $n$ : número total de amostras e  $c$ : número total de classes.

Foi considerada a melhor classificação a que apresentou o maior valor da estimativa do coeficiente Kappa, testado pelo teste  $Z$  ao nível de 5% de probabilidade, utilizando a Equação 3 (CONGALTON e MEAD, 1983).

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}} \quad (3)$$

$$\text{var}(\hat{K}) = \frac{1}{n} \left[ \frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (4)$$

$$\theta_1 = \frac{1}{n} \sum_{i=1}^c x_{ii} \quad (5)$$

$$\theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i\oplus} x_{\oplus i} \quad (6)$$

$$\theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_{ii} (x_{i\oplus} + x_{\oplus i}) \quad (7)$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_{ij} (x_{j\oplus} + x_{\oplus j})^2 \quad (8)$$

em que,  $\hat{K}_1, \hat{K}_2$ : coeficientes Kappa;  $x_{ij}$ : elemento da matriz de erros na linha  $i$  e coluna  $j$ ;  $x_{j\oplus}$ : somatório da linha  $j$ ;  $x_{\oplus j}$ : somatório da coluna  $j$ .

### Identificação da assinatura espectral

A identificação da assinatura espectral foi realizada pela representação gráfica dos valores de reflectância em função dos comprimentos de onda.

### Identificação dos comprimentos de onda hiperespectrais por correlação multivariada

Foi calculado o coeficiente de correlação entre cada um dos comprimentos de onda hiperespectrais com o índice de severidade de doença correspondente em cada

uma das épocas de avaliação. Os comprimentos de onda que apresentaram correlações significativas foram identificados bem como a frequência desta significância, considerando todas as épocas de avaliação. Os comprimentos de onda que apresentaram maior frequência desta correlação significativa foram os escolhidos para quantificar o nível de severidade da doença.

### **Identificação de comprimentos de onda hiperespectrais por regressão por Mínimos Quadrados Parciais (PLS)**

Entre as técnicas multivariadas de regressão, optou-se pela regressão por Mínimos Quadrados Parciais (PLS). Esta é capaz de lidar com grande número de variáveis respostas, altamente correlacionadas e utilizando pequenos conjuntos de observações (TEÓFILO et al., 2009). Regressão PLS foi então aplicado a um conjunto de 601 variáveis explicativas (comprimentos de onda contendo medidas de reflectância) conjugadas a uma variável dependente (AFN).

A base para construção de modelos por regressão PLS é a Análise de Componentes Principais (PCA). De forma simplificada pode ser explicada pela decomposição espectral de uma matriz de variáveis dependentes ( $Y$ ) em seus *scores* ( $U$ ) e *loadings* ( $Q$ ). *Score* é a coordenada de cada objeto ao longo de um eixo (componente principal). *Loading* é a participação de cada medida em um eixo, ou quanto cada variável original contribui. De igual modo, uma matriz de variáveis independentes ( $X$ ) decomposta em função de seus *scores* ( $T$ ) e *loadings* ( $P$ ), tal que, há uma relação entre os *scores*  $T$  e  $U$ , onde se pode determinar um coeficiente angular  $b$  ( $\tan \alpha$ ) entre os eixos, também conhecido como coeficiente de regressão. É representado pela Equação 9.

$$b = U'T/T'T \quad (9)$$

A variável dependente a ser predita ( $Y_p$ ) é dada pela Equação 10.

$$Y_p = TbQ' + \varepsilon \quad (10)$$

em que,  $\varepsilon$  = vetor de resíduos.

Inicialmente, a presença de valores atípicos (*outliers*) foi checada pela estatística de z-score robusto, utilizado por DASZYKOWSKI et al. (2007), o qual identifica medidas anômalas a partir de resíduos entre valores medidos e preditos determinados pela regressão PLS. É dado pela Equação 11.

$$\left| \frac{e_i - \text{mediana}\{e_i\}_{i=1}^n}{Q_n} \right| > C \quad (11)$$

em que,  $e_i$ :  $i$ -ésimo resíduo;  $C$ : limite de corte dada a distribuição normal (3 vezes o desvio padrão);  $n$ : número de observações;  $Q_n$ : estimador de escala.

$$Q_n(y_1, \dots, y_n) = 2.2219\{|y_i - y_j|; 1 \leq i < j \leq n\}_{(k)} \quad (12)$$

onde,  $k = 0,5 \cdot h(h - 1)$ ;  $h = \left(\left[\frac{n}{2}\right] + 1\right)$ ;

em que,  $k$  corresponde a ordem estatística indicando o maior valor de  $Q_n$  calculado em função da diferença entre resíduos ( $y_i - y_j$ ).

Os dados utilizados para a regressão PLS foram pré-processados pela técnica de centrar na média, visto ser o método indicado para informações de espectrometria (FERREIRA et al., 1999), dado pela Equação 13.

$$x_c = x - \mu(x) \quad (13)$$

em que,  $x$ : valor do componente na coluna;  $\mu(x)$ : média do componente na coluna.

Para determinar os comprimentos de onda que melhor representam o modelo, foi feita, em cada DAE de tomada da reflectância, a divisão das informações aleatórias em dois grupos, calibração e validação. Para isso, foi considerado as observações sem a presença de *outliers*. O grupo de calibração foi composto de 70% das observações na esperança de se ter todas as variações das amostras originais representadas. Antes da divisão dos grupos as observações foram aleatorizadas de forma a eliminar tendências. Em seguida, foi estabelecida a correlação entre as reflectâncias em todos os comprimentos de onda e a severidade da doença, utilizando o grupo de calibração. Os valores absolutos dessa correlação foram ordenados na forma decrescente. Com as correlações ordenadas foram construídos subgrupos de variáveis independentes, em que o primeiro subgrupo correspondeu ao comprimento de onda de melhor correlação, e os subgrupos subsequentes foram formados pelo subgrupo anterior mais o comprimento de onda de maior correlação que ainda não pertencia a nenhum subgrupo. Assim, o último subgrupo formado teve todos os comprimentos de ondas utilizados. Cada subgrupo foi submetido à regressão PLS e uma medida de qualidade do modelo ( $q$ ) foi determinada pela razão entre a correlação e a Raiz do Erro Quadrático Médio (RMSE) normalizado dos dados medidos e previstos. O RMSE é dada pela Equação 14.

$$RMSE = \sqrt{\frac{\sum_1^n (y_i - \hat{y}_i)^2}{n}} \quad (14)$$

em que:  $n$  é o número de amostras;  $y_i$  é valor real da variável dependente e  $\hat{y}_i$  o valor estimado pelo modelo de regressão.

Para estimativa do RMSE, usou-se a estratégia de validação cruzada deixando um de fora (*leave-one-out*) na contabilização dos erros de previsão. Esse processo calibra os modelos da regressão PLS iterativamente usando todos os dados, exceto um. Em cada iteração, uma amostra diferente é deixada de fora a partir dos dados até que todas estas amostras fiquem de fora uma vez. Os valores para as amostras deixadas de fora da calibração são então previstos e os resíduos de previsão computados.


Os comprimentos de onda selecionados foram aqueles que constituírem o modelo com a melhor medida de qualidade ( $q$ ). Este processo de seleção de comprimentos de onda foi baseado do trabalho de TEÓFILO et al. (2009).

Os métodos utilizados foram desenvolvidos em Matlab R12.1 (MathWorks, Natick, USA). Para a regressão PLS, utilizou-se o pacote OPS Toolbox para Matlab (TEÓFILO et al., 2009). Os algoritmos de regressão PLS adotados no pacote OPS Toolbox foram o SIMPLS (JONG, 1993) e Fast Kernel PLS (DAYAL e MacGREGOR, 1997).

Após definido o modelo pela regressão PLS, esta foi utilizada nas observações do subgrupo de validação. Foi então calculado as correlações entre os valores medidos e estimados de forma a quantificar a significância do modelo do subgrupo de validação.

## RESULTADOS

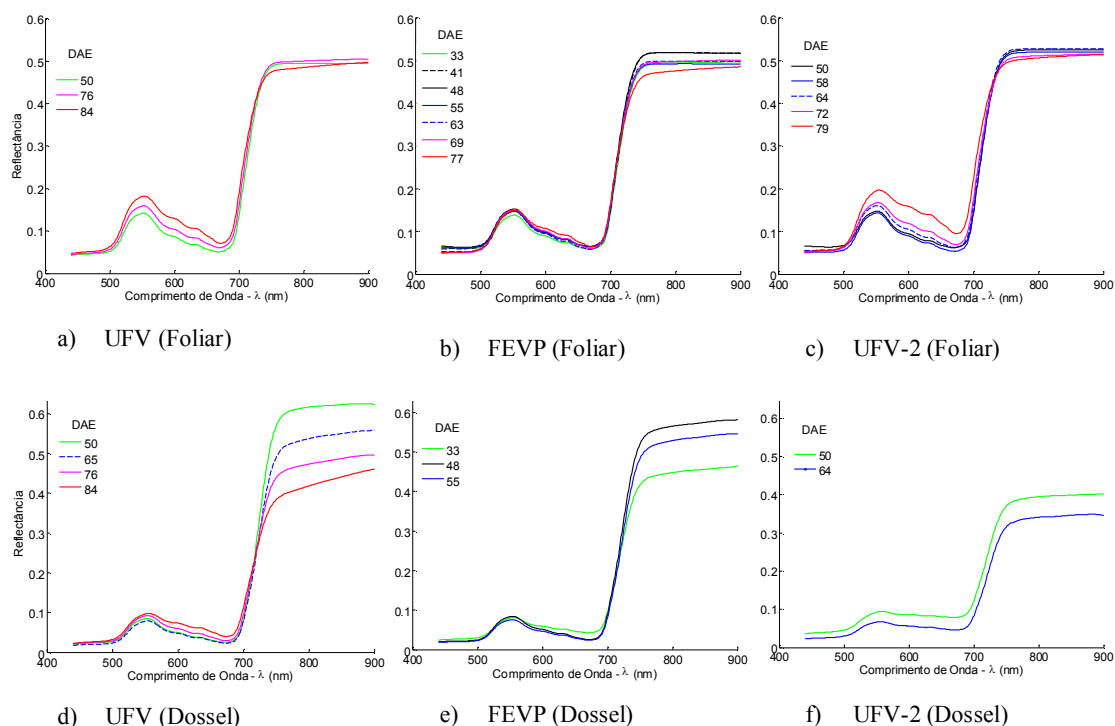
A mancha-angular apresentou valores moderados de severidade conforme critérios utilizados por MODA-CIRINO et al. (2012), considerando as leituras feitas no estágio fenológico R8. A doença surgiu a partir do florescimento, atingindo níveis mais críticos durante a formação e maturação das vagens. No experimento UFV houve atraso para a determinação dos níveis de severidade de doença pelo fato de ocorrência de chuva em Viçosa no dia de coleta de dados (Figura 1). As produtividades médias nos experimentos foram de 1.261, 1.621 e 1.725 kg.ha<sup>-1</sup> para FEVP, UFV e UFV-2, respectivamente. Somente FEVP esteve abaixo da produtividade média de Minas Gerais (1.572 kg.ha<sup>-1</sup>) para a safra de 2011/2012 (CONAB, 2013). Esse fato é justificado pela maior severidade da mancha-angular neste experimento (Figura 1). O ciclo de vida dos feijoeiros foi de 90 dias para FEVP e de 95 dias para UFV e UFV-2.



**Figura 1.** Área de severidade da mancha-angular em função dos dias após emergência(DAE) nos três experimentos.

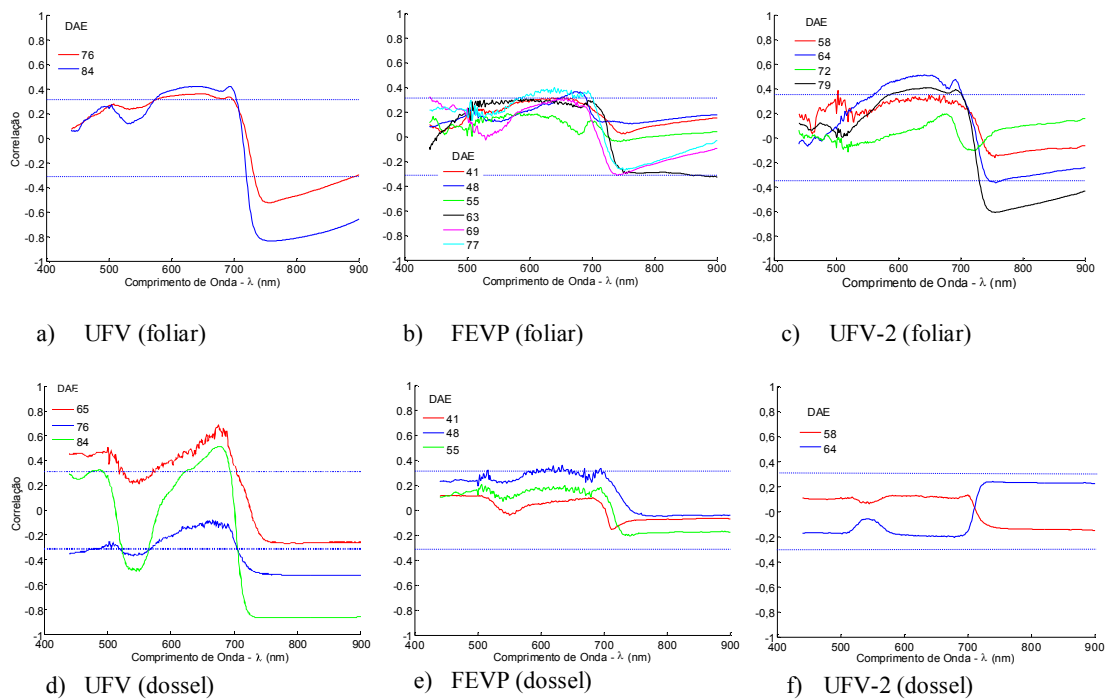
As assinaturas espectrais do feijoeiro para as reflectâncias foliar e dossel estão apresentadas na Figura 2. As reflectâncias de dossel foram diferentes para UFV-2 em relação à UFV e FEVP, em que as reflectâncias de UFV-2 a partir do comprimento de onda de 760 nm foram muito baixas, não ultrapassando o valor de 0,4. E também, pela ocorrência de maiores reflectâncias entre os comprimentos de onda de 600 a 700

nm, aproximadamente, identificadas em UFV-2. Esse fato se deu em função do pouco crescimento das plantas deste experimento (causa não identificada), não ocorrendo assim o fechamento do dossel, ficando as leituras de reflectância do feijoeiro confundidas com solo e plantas daninhas.



**Figura 2.** Assinatura espectral média foliar e do dossel do feijoeiro nos experimentos de Viçosa e Oratórios a partir do último dia após emergência (DAE) sem doença.

Na Figura 3 são descritas as correlações da AFN com as reflectâncias, obtidas nos DAE em que foram feitas as tomadas da reflectância (Tabela 1), após a detecção da doença em campo. A linha tracejada na horizontal representa os limites de significância para as correlações positivas e negativas. A maior parte das correlações significativas foram constatadas a partir do comprimento de onda de 550 nm. O experimento de FEVP apresentou poucas datas com comprimentos de onda significativos. Já UFV-2 dossel não apresentou significância para qualquer comprimento de onda.



**Figura 3.** Correlações entre reflectâncias e área foliar necrosada (AFN) dos experimentos de Viçosa e Oratórios.

Informações relativas aos comprimentos de onda de correlações significativas para reflectâncias foliar e de dossel (Figura 3) estão descritos nas Tabelas 2 e 3. Observando os comprimentos de onda selecionados por meio da correlação da reflectância foliar e de dossel com AFN nota-se que todas as faixas espectrais estão presentes, no caso, azul (440-510 nm), verde (520-590 nm), vermelho (630-685nm), *red-edge* (690-730 nm) e infravermelho (maior que 760 nm), conforme as bandas espectrais do satélite RapidEye. As reflectâncias foliares de FEVP com 55 DAE e UFV-2 com 72 DAE; e, as reflectâncias de dossel de FEVP com 48 DAE e UFV-2, não apresentaram nenhuma correlação significativa e foram excluídas das respectivas tabelas.

**Tabela 2.** Comprimentos de onda com reflectâncias foliares correlacionadas significativamente com área foliar necrosada

Exp.	DAE	Comprimentos de onda de correlação significativa ( $\lambda$ )	Maior $r^1$	$\lambda$ de maior r
UFV	76	576-590; 591-698; 733-759; 760-	0,5273***	759

893				
	84	574-704; 721-900	0,8371***	759
FEVP	41	636-638; 645-646; 650-656	0,3162*	655
	48	650-690	0,3640*	672
	63	858-866; 868-900	0,3289*	900
	69	440-442; 659; 739-740	0,3207*	441
	77	594-597; 600-603; 607-668; 677; 681-683; 686-698	0,3966*	640
UFV-2	58	502-503	0,3872*	503
	64	561-702; 746-766	0,5112**	642
	79	587-701; 731-900	0,6107***	755

(<sup>1</sup>) Nível de significância: \*  $p \leq 0,05$ ; \*\*  $p \leq 0,01$ ; \*\*\*  $p < 0,001$ ; ns=não significativo. Exp.: nome do experimento; DAE: dias após emergência;  $\lambda$ : comprimentos de onda (nm); r: valor de correlação significativa.

**Tabela 3.** Relação de comprimentos de onda com reflectâncias sobre dossel correlacionadas significativamente com área foliar necrosada

Exp.	DAE	Comprimentos de onda de correlação significativa ( $\lambda$ )	$\lambda$ de maior r	
			Maior $r^1$	maior r
UFV	65	440-518; 521-524; 572-573; 576-704	0,6875***	676
	76	440-480; 485; 521-568; 706-900	0,5257***	870
	84	477-491; 524-565; 624-694; 707-900	0,8675***	759
FEVP	48	515-516; 581; 588; 594-595; 597-598; 600-604 607-616; 618-621; 626-630; 632-643; 647-648 653; 669; 687-688; 693-695	0,3606*	634

(<sup>1</sup>) Nível de significância: \*  $p \leq 0,05$ ; \*\*  $p \leq 0,01$ ; \*\*\*  $p < 0,001$ ; ns=não significativo. Exp.: nome do experimento; DAE: dias após emergência;  $\lambda$ : comprimentos de onda (nm); r: valor de correlação significativa.

Os resultados da regressão PLS para reflectâncias foliar e de dossel (Tabela 4) apresentou RMSE próximos entre os grupos de calibração e validação, a excessão do

experimento FEVP com 63 DAE, em reflectância foliar. Nesta Tabela foram consideradas somente as datas que apresentaram significância estatística do valor de correlação ( $r$ ) nos grupos de calibração e validação. Esta condição não foi observada para reflectâncias de dossel nos experimentos FEVP e UFV-2.

**Tabela 4.** Medidas de correlação e de erro para modelos provenientes da regressão PLS para os grupos de calibração e validação em reflectâncias foliar e de dossel

Tipo	Exp.	DAE	Calibração		Validação	
			$r^{(1)}$	RMSE	$r^{(1)}$	RMSE
Foliar	UFV	76	0,6878	2,50	0,7616	2,98
		84	0,8962	3,15	0,7042	6,30
	FEVP	63	0,7259	9,64	0,5943	9,89
		69	0,6775	2,28	0,6735	10,00
		77	0,8380	3,53	0,8521	3,96
	UFV-2	72	0,7372	2,18	0,7015	3,23
		79	0,7249	5,38	0,8837	5,44
	Dossel	UFV	65	0,6935	4,31	0,6250
76			0,5785	3,31	0,6259	3,72
84			0,8294	4,07	0,9267	2,84

<sup>(1)</sup> Nível de significância: \*  $p \leq 0,05$ ; \*\*  $p \leq 0,01$ ; \*\*\*  $p < 0,001$ ; ns=não significativo. Exp.: nome do experimento; DAE: dias após emergência; r: valor de correlação significativa; RMSE: Raiz do Erro Quadrático Médio.

A relação dos comprimentos de onda identificados pela regressão PLS (Tabela 4) estão apresentados na Tabela 5. Estes comprimentos de onda estão também presentes em todas as faixas espectrais (azul, verde, vermelho, *red-edge* e infravermelho),

conforme as bandas espectrais do satélite RapidEye. Nos experimentos UFV-2 e FEVP para dossel não houve correlação significativa na regressão por PLS.

**Tabela 5.** Comprimentos de onda selecionados pela regressão PLS

<b>Tipo</b>	<b>Exp.</b>	<b>DAE</b>	<b>Maior Coef. Regr.</b>	<b>Comprimentos de onda</b>
Foliar	UFV	76	659	658-660; 747-759
		84	744	720-900
	FEVP	63	584	562-563; 568-701; 742-900
		69	502	440-509; 513-520; 537-538; 544-546; 548-710; 720-864
		77	503	440-501; 503-507; 510-519; 523-525; 529; 534; 537; 542; 545-546; 548-549; 552; 555; 558-706; 713-897
	UFV-2	72	715	516; 519-520; 711-712; 714-728; 730-732; 858-900
79		746	746-779	
Dossel	UFV	65	651	440-462; 481-497; 499-501; 506; 621-622; 625; 629-634; 638; 641-694
		76	723	440-595; 598-600; 604; 702-900
		84	883	883

Exp.: nome do experimento; DAE: dias após emergência

## DISCUSSÃO

Em função dos resultados apresentados foi observado que a presença da mancha-angular pode ser determinada e quantificada em diferentes estádios fenológicos utilizando reflectâncias hiperespectrais.

As assinaturas espectrais foliar (Figura 2) demonstraram alterações no decorrer do ciclo da cultura à medida que ocorre o aumento da doença. Nas reflectâncias foliares houve alterações perceptíveis na faixa do visível e infravermelho próximo. Nas reflectâncias do dossel as mudanças no infravermelho são mais nítidas. Na região espectral do visível, o padrão da resposta espectral foliar diferiu-se da do dossel, visto que as reflectâncias do dossel tenderam a valores menores que as reflectâncias foliares na faixa do visível (Figura 2). A assinatura espectral do dossel é influenciada pela concentração de folhas. Na região do visível, a assinatura espectral é predominantemente influenciada pela absorção da energia pelos pigmentos fotossintetizantes (PONZONI e SHIMABUKURO, 2009). Dessa maneira, uma maior concentração dos pigmentos fotossintetizantes devido a uma maior concentração de folhas acarretou a diminuição da reflectância do dossel em relação a reflectância foliar.

Na região espectral do infravermelho próximo, não houve relação definida entre reflectância foliar e a dossel. A reflectância do dossel era menor ou maior que a foliar dependendo da data de aquisição de dados, com exceção do experimento UFV-2, onde a reflectância do dossel foi menor que a foliar. A absorção da radiação do infravermelho próximo é baixa, portanto com alta reflectância e transmitância (NOVO, 2008; PONZONI e SHIMABUKURO, 2009). A reflectância do dossel pode ser maior que a foliar devido ao espalhamento da radiação entre as camadas de folhas, ou menor devido ao sombreamento mútuo entre folhas. Dosséis mais homogêneos, com grande quantidade de folhas verdes, são altamente refletivos no infravermelho próximo, mas refletem muito pouco no vermelho. Em dosséis menos densos, o efeito da camada inferior do dossel e das sombras deve ser considerado na análise dos resultados (PONZONI e SHIMABUKURO, 2009).

As reflectâncias foliares do infravermelho próximo tendem a alcançar um patamar a partir de 760 nm, com valores próximos a 0,5. Neste caso, PONZONI e SHIMABUKURO (2009) mencionam que reflectâncias sobre uma única camada de

folhas, cinquenta por cento da radiação eletromagnética incidente sobre o infravermelho próximo seria refletida e cinquenta por cento seria transmitida através da folha. No dossel, observa-se que as curvas de reflectância tendem a um crescimento ascendente após o comprimento de onda de 760 nm, demonstrando assim, uma dinâmica diferenciada às reflectâncias foliar. PONZONI e SHIMABUKURO (2009) também explicam que em dossel, a reflectância no infravermelho próximo aumentaria à medida que ocorre aumento do número de camadas, podendo chegar a um patamar a partir de uma camada de 5 ou 6 folhas.

As alterações espectrais apresentadas na Figura 2 também poderiam ser influenciadas por outros fatores como temperatura, umidade relativa do ar, umidade da folha, do dossel e do solo, ou por qualquer estresse na planta além da doença. No entanto, as Tabelas 2, 3 e 5 apresentaram diversos comprimentos de onda relacionados de forma significativa com a mancha-angular, confirmando a possibilidade de detectar a doença por reflectâncias hiperespectrais. Os comprimentos de onda selecionados nas Tabelas 2, 3 e 5 estão presentes nas faixas espectrais do azul, verde, vermelho, *red-edge* e infravermelho. Isto é justificado pelo fato de que diferentes sintomas da doença afetam a interação entre as plantas e a radiação eletromagnética em diversas faixas espectrais, no caso, do azul ao infravermelho (WEST et al., 2003). Analisando as maiores correlações para ambas as medições, foliar e dossel, nota-se que, nas quatorze datas de medições com correlações significativas (Tabelas 2 e 3), duas foram na faixa espectral do azul, seis na faixa espectral do vermelho, quatro na faixa espectral entre o infravermelho próximo e o *red-edge* e duas na faixa espectral do infravermelho próximo. A faixa espectral do vermelho apresentou comprimentos de onda de maior frequência entre aqueles determinados por correlação. Considerando os maiores coeficientes de regressão PLS (Tabela 5), nota-se que, em dez datas de medição, duas estiveram presentes nas faixas espectrais do azul, duas no vermelho, duas no *Red-edge* e duas na faixa do intervalo entre *red-edge* e infravermelho próximo (730-760 nm). Com relação à frequência de ocorrência de cada faixa espectral, considerando a regressão PLS para as medições foliar (Tabela 5) a única faixa espectral que teve representante em todas as datas foi o comprimento de onda entre o *red-edge* e infravermelho próximo. Para as medições do dossel, em todas as datas apareceram comprimentos de ondas acima do *red-edge* (690 nm). Dessa maneira, considerando as correlações e

regressão PLS, destacam-se as faixas espectrais do vermelho, intervalo entre red-edge e infravermelho próximo, e azul para detecção da doença.

A predominância da faixa do vermelho na correlação com a severidade da doença estaria ligada à diminuição dos pigmentos fotossintetizantes, em especial, a clorofila, dado o aumento da doença durante o ciclo da cultura. Entre os pigmentos, a clorofila é o predominante, compreendendo sessenta por cento do total (PONZONI e SHIMABUKURO, 2009). É ainda o principal pigmento que influencia na reflectância no espectro do visível (XUE e YANG, 2009; PONZONI e SHIMABUKURO, 2009). A ação do fungo provoca necrose em função do dano à membrana e da morte celular após o fungo ter penetrado os estômatos da folha (MAHLEIN et al., 2013). Assim, com a presença de clorose ou necrose ocorre o aumento da reflectância na faixa do visível, especialmente nos comprimentos de onda de absorção da clorofila (WEST et al., 2003; BLACKBURN, 1998). Alguns trabalhos, estudando a relação de reflectâncias com severidades de doenças, encontraram comprimentos de onda no vermelho, próximas às indicadas no presente trabalho. JONES et al. (2010), utilizando regressão linear múltipla para estimativa de doenças em folha de tomate, determinaram os comprimentos de onda de 633 a 635, 650, 660 e 672 nm como os de melhor representatividade da severidade. O comprimento de onda de 672 nm, por exemplo, coincide com o de maior correlação apresentado na Tabela 2 em FEVP, DAE 48. O comprimento de 650 nm é também destacado na Tabela 2 em FEVP, DAE 41 e 48. Já o comprimento de 660 nm é próximo a 659 nm determinado pela regressão PLS (Tabela 5), em UFV, DAE 76, para reflectância foliar. PRABHAKAR et al. (2013), comparando a diferença de comprimentos de onda hiperespectral entre plantas saudáveis e doentes, encontraram a maior diferença de reflectância em 689 e 685 nm, seguido por 647 e 644 nm, para épocas de cultivo em primavera e verão, respectivamente. Os mesmos autores mencionam o comprimento de onda de 669 nm como de maior sensibilidade para a estimativa da doença em ambos os períodos. Valores próximos a estes podem ser destacados na Tabela 3 entre as correlações significativas de FEVP DAE 48, por exemplo, para os comprimentos de onda de 643, 647, 648, 669, 687 e 688 nm.

A faixa espectral do *red-edge* funciona como um indicador eficiente de estresses em plantas (SHAFRI e HAMDAN, 2009). Aumento de reflectância em comprimentos de onda em torno de 670 nm (vermelho), onde ocorre absorção pela

clorofila, faz com que a transição brusca no espectro na região do visível para o infravermelho (o *red-edge*) venha a se deslocar para comprimentos de onda mais curtos (WEST et al. 2003), tornando-se assim um bom indicador da presença de doença. O valor de comprimentos de onda de maior correlação foi igual a 759 nm, nos experimentos UFV (foliar e dossel) aos 84 DAE, e está próximo aos comprimentos de onda determinados por alguns autores. YANG (2010), usou reflectâncias hiperespectrais de dossel para estimativa de doenças de arroz e encontrou uma faixa espectral com início em 757 nm. JONES et al. (2010), utilizando regressão PLS, identificaram os comprimentos de onda entre 750-760 nm, considerados significativos e altamente relacionados com a severidade da doença em folhas de tomate.

Alterações de reflectância na região do infravermelho estaria ligada à alterações na estrutura interna do tecido em função da presença da doença (YANG, 2010; MALTHUS e MADEIRA, 1993; KNIPLING, 1970), em que, uma degradação na estrutura das folhas levaria a uma diminuição do espalhamento interno e a um aumento na transmitância da folha nesta região. Neste sentido, PONZONI e SHIMABUKURO (2009) mencionam que de maneira geral, quanto mais lacunosa for a estrutura interna foliar, maior será o espalhamento interno da radiação incidente, e conseqüentemente, maiores serão também os valores de reflectância. PONZONI e SHIMABUKURO (2009) mencionam também que a menor reflectância na região do infravermelho pode ser atribuída à invasão das hifas nos espaços intercelulares, que tendem a compactar a estrutura interna das folhas.

A faixa espectral do azul também apareceu como importante em algumas datas de medições. Os pigmentos predominantes na folha absorvem radiação na faixa espectral do azul, mas no vermelho, a absorção da radiação é feita somente pela clorofila (PONZONI e SHIMABUKURO, 2009). Assim, a faixa espectral do azul seria menos sensível à presença da doença do que o vermelho, principalmente em reflectâncias foliares. MAHLEIN et al. (2013) informam que a faixa espectral do azul não seria indicada para associação da clorofila com a severidade da doença, visto a sobreposição que ocorre nesta faixa espectral da clorofila com os carotenoides. Por outro lado, a faixa espectral do azul apresentou-se com maior frequência no estudo da resposta espectral do dossel. Neste caso, poderia ter ocorrido influência da degradação foliar com conseqüente diminuição de biomassa,

promovendo maior presença de matérias não-fotossintéticas (cobertura morta), maior entrada de luz e maior exposição da face subjacente ao dossel.

A faixa do verde apresentou menor representatividade quando comparada às demais. Nenhum comprimento de onda da faixa do verde apresentou maior correlação entre reflectância e AFN, e apenas uma data apresentou maior coeficiente de regressão PLS (FEVP / 63 DAE) em 584 nm, reflectâncias tipo foliar. No entanto, algumas datas apresentaram comprimentos de onda selecionados nesta faixa espectral, considerando as correlações e modelos de regressão PLS. Ocorre um aumento significativo na reflectância da faixa espectral verde com a diminuição da concentração de clorofila (YANG, 2010). WEST et al. (2003) citam que a absorvância reduzida neste comprimento de onda é comum em plantas doentes e é o resultado da redução de níveis de clorofila devido à doença. Foram também apresentados na Tabela 5 comprimentos de onda que compreendem o final do azul e início do verde (490-530 nm). XUE e YANG (2009) definem esta faixa espectral entre o azul e o verde como *blue-edge*, semelhante a *red-edge*, que seria a inclinação máxima da curva de reflectância durante as faixas azul e verde. HUANG et al. (2012) indicam a relação da reflectância foliar de arroz com a severidade da doença em função da maior representatividade do comprimento de onda em 520 nm (*blue-edge*) e de 710 nm (*red-edge*). MALTHUS e MADEIRA (1993) citam que medidas de reflectância foliar no comprimento de onda de 525 nm (*blue-edge*) e de 580 nm (verde) são altamente correlacionadas com níveis de infecção da doença de feijão estudada; e também, o comprimento de onda de 715 nm (*red-edge*) como um índice útil para a detecção de mudanças espectrais induzidas pela doença.

Os comprimentos de onda e faixas espectrais selecionados poderiam ser utilizados em plataformas de visão artificial para uso em máquinas agrícolas e/ou em contato com a folha para a estimativa da severidade da doença. No entanto, apesar dos resultados indicarem uma relação significativa da doença em diversos comprimentos de onda, não foi detectado um intervalo comum destes comprimentos de onda considerando todas as datas juntas. Este fato estaria influenciado por variações no volume de irrigação e por condições climáticas, o que pode alterar as reflectâncias de folhas e de dossel. Assim, há a necessidade de levantamento de outras variáveis dentro da lavoura que estariam relacionadas à doença, de forma a melhorar a compreensão do comportamento espectral da cultura durante seu ciclo. Isto inclui a

quantificação de percentuais dos pigmentos fotossintetizantes, de água presente nas folhas e de medidas de clima dentro do dossel das culturas.

## CONCLUSÃO

Os resultados indicam que as mudanças na resposta espectral na folha e no dossel do feijoeiro foram influenciadas pela severidade de mancha-angular. As reflectâncias sofreram alterações em todas as faixas espectrais em função do aumento da severidade de doença. No entanto, as faixas do vermelho e intervalo entre o *red-edge* e o infravermelho, segundo bandas espectrais do satélite RapidEye, mostraram-se como as mais sensíveis à presença da mancha-angular.

A metodologia utilizada permitiu a discriminação dos comprimentos de onda para estimar a severidade da mancha-angular em diferentes estádios fenológicos. No entanto, a inclusão de outras variáveis relacionadas à fisiologia da planta e às variações climáticas durante o ciclo da cultura pode melhorar a acurácia na quantificação da severidade da doença.

## BIBLIOGRAFIA

BEEBE, S. E. Common bean breeding in the tropics. In: Janick, J. (Eds.) **Plant breeding reviews**. New Jersey: Wiley-Blackwell. 2012. v. 36, p. 357-426.

BLACKBURN, G. A. Hyperspectral remote sensing of plant pigments. **Journal of Experimental Botany**, v.58, p.844-867, 2007

CAO, X.; LUO, Y.; ZHOU, Y.; DUAN, X.; CHENG, D. Detection of powdery mildew in two winter wheat cultivars using canopy hyperspectral reflectance. **Crop Protection**, v. 45, p. 124-131, 2013.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v.20, p.37-46, 1960.

CONAB. **Acompanhamento da Safra Brasileira. Grãos: Safra 2012/2013**. Disponível em: <[http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13\\_07\\_09\\_09\\_04\\_53\\_boletim\\_graos\\_junho\\_\\_2013.pdf](http://www.conab.gov.br/OlalaCMS/uploads/arquivos/13_07_09_09_04_53_boletim_graos_junho__2013.pdf)>. Acesso em 21/10/2013.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v.37, n.1, p.35-46, 1991.

CONGALTON, R.G.; MEAD R.A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering and Remote Sensing, Maryland**, v.49, n.1, p.69-74, 1983.

DASZYKOWSKI, M.; SERNEELS, S.; KACZMAREK, K.; et al. TOMCAT: A MATLAB toolbox for multivariate calibration techniques. **Chemometrics and Intelligent Laboratory Systems**, v. 85, n. 2, p. 269–277, 2007.

DAYAL, B. S.; MacGREGOR, J. F. IMPROVED PLS ALGORITHMS. **Journal of Chemometrics**, v. 11, p. 73-85, 1997.

FERREIRA, M. M. C. et al. Quimiometria I: calibração multivariada , um tutorial. **Química Nova**, v.22, n.5, p. 1-14, 1999.

FRANKE, J.; MENZ, G. Multi-temporal wheat disease detection by multi-spectral remote sensing. **Precision Agriculture**, v. 8, n. 3, p. 161-172, 2007.

HUANG, J.; LIAO, H.; ZHU, Y.; et al. Hyperspectral detection of rice damaged by rice leaf folder (*Cnaphalocrocis medinalis*). **Computers and Electronics in Agriculture**, v. 82, p. 100–107, 2012.

JONES, C. D.; JONES, J. B.; LEE, W. S. Diagnosis of bacterial spot of tomato using spectral signatures. **Computers and Electronics in Agriculture**, v. 74, n. 2, p. 329-335, 2010.

JONG, S. de. SIMPLS: An alternative approach to partial least squares regression. **Chemometrics and Intelligent Laboratory Systems**, v. 18, n. 3, p. 251-263, 1993.

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.

MAHLEIN, A. K. et al. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. **Precision Agriculture**, v. 11, n. 4, p. 413-431, 2010.

MAHLEIN, A. K.; RUMPF, T.; WELKE, P. et al. Development of spectral indices for detecting and identifying plant diseases. **Remote Sensing of Environment**, v. 128, p. 21-30, 2013.

MALTHUS, T. J.; MADEIRA, A. C. High Resolution Spectroradiometry : Spectral Reflectance of Field Bean Leaves Infected by *Botrytis fabae*. **Remote Sensing of Environment**, n.. 45, p. 107-116, 1993.

MAPA. **Vegetal: Feijão.** Disponível em: <<http://www.agricultura.gov.br/vegetal/culturas/feijao>>. Acesso em 21/10/2013.

MODA-CIRINO, V.; RAMALHO, M. A. P.; ABREU, A. F. B. [et al.]. Mancha-angular. In: PAULA JÚNIOR e WENDLAND (Eds) **Melhoramento genético do**

**feijoeiro-comum e prevenção de doenças.** Viçosa, MG: EPAMIG Zona da Mata. 2012. Cap. 4, p. 71-81.

NOVO, E. M. L. M. Sensoriamento Remoto: princípios e aplicações. São Paulo: Edgard Blucher, 2008. v. 01, 363 p.

PAULA JÚNIOR, T. J.; ZAMBOLIM, L. Doenças. In: VIEIRA, C., PAULA JÚNIOR, T.J. e BORÉM, A. (Eds.) **Feijão**. Viçosa: Editora UFV. 2006. cap. 13, p. 359-414.

PEDRINI, H.; SCHWARTZ, W. R., **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. São Paulo: Ed. Thomson Learning, 2008. 508p.

PONZONI, F. J.; SHIMABUKURO, Y. E. Sensoriamento Remoto no Estudo da Vegetação. São Jose dos Campos, SP: Ed. Parêntese, 2009. 135p.

PRABHAKAR, M.; PRASAD, Y. G.; DESAI, S. et al. Hyperspectral remote sensing of yellow mosaic severity and associated pigment losses in Vigna mungo using multinomial logistic regression models. **Crop Protection**, v. 45, p. 132-140, 2013.

SHAFRI, H. Z. M.; HAMDAN N. Hyperspectral Imagery for Mapping Disease Infection in Oil Palm Plantation Using Vegetation Indices and Red Edge Techniques. **American Journal of Applied Sciences**. v. 6, n. 6, p. 1031-1035, 2009.

SONG, S. et al. Wavelength selection and spectral discrimination for paddy rice , with laboratory measurements of hyperspectral leaf reflectance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 5, p. 672-682, 2011.

TEÓFILO, R. F.; MARTINS, J. P. A.; FERREIRA, M. M. C. Sorting variables by using informative vectors as a strategy for feature selection in multivariate regression. **Journal of Chemometrics**, v. 23, n. 1, p. 32-48, 2009.

WEST, J. S.; BRAVO, C.; OBERTI, R. et al. The potential of optical canopy measurement for targeted control of field crop diseases. **Annual review of phytopathology**, v. 41, p. 593-614, 2003.

YANG, C. M.. Assessment of the severity of bacterial leaf blight in rice using canopy hyperspectral reflectance. **Precision Agriculture**, v.11, p.61-81, 2010.

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

ZHANG, H.; HU, H.; ZHANG, X. et al. Estimation of rice neck blasts severity using spectral reflectance based on BP-neural network. **Acta Physiologiae Plantarum**, v. 33, n. 6, p. 2461-2466, 2011.

## CAPÍTULO 2

---

### ESTIMATIVA DE SEVERIDADE DO MOFO-BRANCO EM LAVOURAS DE FEIJÃO UTILIZANDO SENSORES HIPER E MULTIESPECTRAL

### ESTIMATIVE OF WHITE MOLD SEVERITY IN COMMON BEAN CROP USING HYPER AND MULTISPECTRAL SENSORS UNDER

#### RESUMO

Este estudo objetivou identificar comprimentos de onda e faixas espectrais provenientes de reflectâncias hiper e multiespectrais, utilizando regressão PLS; e, promover avaliação comparativa destes métodos e de índices de vegetação (DVI, GNDVI, MCARI, MCARI2, MSAVI, NDVI, OSAVI, RDVI, TCARI, MCARI/OSAVI, TCARI/OSAVI) para estimar severidade de mofo-branco em feijão. Foram implantados experimentos nos municípios de Viçosa e de Oratórios, Estado de Minas Gerais. Reflectâncias hiperespectrais foram obtidas com espectraloradiômetro, com faixa útil entre 440 e 900 nm. Reflectâncias multiespectrais foram obtidas de imagens de cinco bandas espectrais (vermelho, verde, azul, *Red-edge* e infravermelho). Índices de vegetação hiper e multiespectrais foram calculados para determinar aqueles que melhor estimam a severidade do mofo-branco. Os índices de severidade da doença para o mofo-branco nos dois experimentos foram baixos. Em Viçosa, a média foi de 5,8% e em Oratórios, 7,4%. Os métodos utilizados nesse estudo mostraram que as alterações de reflectância no feijoeiro provocadas pela ação do mofo-branco podem indicar a presença da doença a partir do último estágio vegetativo da cultura (V4). Modelos matemáticos com base em comprimentos de onda selecionados por regressão PLS e por índices de vegetação, utilizando reflectâncias hiperespectrais, tiveram melhor desempenho para estimar mofo-branco em relação aos modelos utilizando reflectâncias multiespectrais. A banda do *red-edge* apresentou os comprimentos de onda que melhor estima a severidade do mofo-branco. Quanto aos índices de vegetação, aqueles que são resistentes a efeitos da reflectância de solo estimaram melhor o mofo-branco do

feijoeiro. Entre estes índices, os da família CARI (TCARI e MCARI) e sua razão com OSAVI, juntamente com o DVI, foram os de melhor desempenho.

**Palavras Chaves:** regressão PLS, Dossel, índices de vegetação, *Sclerotinia sclerotiorum*, bandas espectrais.

## **ABSTRACT**

This study aimed to identify wavelengths and spectral ranges from hyper and multispectral reflectance using PLS regression; and to promote comparative evaluation of these methods and vegetation indices (DVI, GNDVI, MCARI, MCARI2, MSAVI, NDVI, OSAVI, RDVI, TCARI, MCARI/OSAVI, TCARI/OSAVI) for estimating the of white mold severity in bean plants. Experiments were implemented in the municipalities of Viçosa and Oratorios, Minas Gerais state. Hyperspectral reflectance were obtained with a spectroradiometer, with useful reading range from 440 to 900 nm. Multispectral reflectances were obtained from images of five spectral bands (red, green, blue, red-edge and infrared). Hiper and multispectral vegetation indexes were calculated to determine those that best estimate the severity of white mold. The white mold disease severities in both experiments were low. In Viçosa, the average was 5,8% and in Oratorios, 7,4%. The methods utilized in this study showed that the changes in crop spectral response caused by the action of white mold may indicate the disease presence from the last crop vegetative stage (V4). Mathematical models based on wavelengths selected by PLS regression and by vegetation indices, using hyperspectral measurements, performed better for estimating white mold over models using multispectral reflectance. The red-edge band presented the wavelengths that best estimate the severity of white mold. The vegetation indices less influenced by soil reflectance presented the best white mold severity estimations. Among those indices, the DVI, CARI family indices (TCARI and MCARI) and its ratio with OSAVI presented the best performance.

**Keywords:** PLS regression, canopy, vegetation index, *Sclerotinia sclerotiorum*, spectral bands

## INTRODUÇÃO

Entre as doenças relacionadas ao período de outono/inverno no Brasil e sob condição de irrigação, o mofo-branco [*Sclerotinia sclerotiorum* (Lib.) de Bary] pode ser considerado uma doença que causa sérios danos à cultura. O mofo-branco, segundo PAULA JÚNIOR et al. (2009, 2012), é a doença do feijoeiro mais destrutiva nas áreas irrigadas do Brasil, notadamente nos plantios realizados nas safras de outono-inverno. Esses autores mencionam que a temperatura e a alta umidade do solo proporcionada pela irrigação contribuem para propiciar condições favoráveis ao desenvolvimento da doença. Torna-se ainda mais severa em locais que ocorrem: cultivos sucessivos da cultura; crescimento vegetativo abundante; e menor arejamento.

A interação patógeno-hospedeiro pode causar modificações em pigmentos, enrugamento da folha, murcha, atrofia, clorose, necrose ou abscisão de partes da planta (PRABHAKAR et al., 2013; PINTER et al., 2003). Por outro lado, a energia eletromagnética refletida das plantas a partir da irradiância solar pode apresentar intensidades diferenciadas quando estas apresentam algum tipo de estresse, visto que esta energia refletida é governada por propriedades de superfície da folha, estrutura interna e distribuição de componentes bioquímicos (BARTON, 2011).

A intensidade das doenças pode, então, ser avaliada através da aplicação de ferramentas de sensoriamento remoto as quais se baseiam na medição da energia refletida ou emitida por um objeto sem que haja contato físico com ele. Neste caso, as medidas de reflectância podem ser utilizadas para avaliação não-destrutiva do estado fisiológico da vegetação e para detectar o impacto do estresse causado por doenças de plantas e deficiências nutricionais (BLACKBURN, 2007). Assim, o uso destas técnicas apresenta vantagens sobre métodos tradicionais de avaliação visual. Isto inclui a utilização de comprimentos de onda que vão além do limite de sensibilidade humana, a capacidade para detectar os primeiros sintomas e,

principalmente, a capacidade de analisarem relações complexas entre várias propriedades da planta (HUANG et al., 2007).

Quanto à utilização da reflectância em comprimentos de onda relativos a características do comportamento espectral da vegetação, podem ser combinadas de forma a realçar alguma característica específica da própria vegetação. Esta relação matemática compõe o chamado índice de vegetação, e destina-se também a minimizar efeitos da irradiância solar, de fundo do solo e de efeitos atmosféricos (EPIPHANIO et al., 1996). Índices de Vegetação têm sido desenvolvidos para compreender variáveis de dossel e servir como base em muitas aplicações de sensoriamento remoto para o gerenciamento da lavoura, visto que eles estão correlacionados com várias propriedades biofísicas importantes (AHAMED et al., 2011). Podem ainda ser úteis na diferenciação entre plantas doentes e saudáveis, bem como na quantificação de doenças (MAHLEIN et al., 2010). Índices de vegetação são considerados relevantes para a detecção de doenças em plantas, visto que o estresse fisiológico manifesta-se em plantas através de alterações no equilíbrio da composição de pigmentos, por exemplo carotenóides, clorofilas e xantofilas (DEVADAS et al., 2009).

Por outro lado, existe a necessidade de implementar técnicas apropriadas para caracterizar a fonte principal da variabilidade espectral e identificar os comprimentos de onda associados às reflectâncias que oferecem o máximo de informação a respeito do problema em estudo (MAHLEIN et al., 2010). Medidas de reflectâncias em diferentes comprimentos de ondas podem apresentar alta correlação entre duas (colinearidade) ou mais medidas (multicolinearidade). Assim, há a possibilidade de redução no número de comprimentos de onda sem perda significativa de informação e sem sacrificar a capacidade de caracterização da cultura (SONG et al., 2011). Neste sentido, a Análise de Componentes Principais (PCA) e Regressão por Mínimos Quadrados Parciais (PLS) são utilizadas na redução da quantidade de comprimentos de ondas em medições hiperespectrais de forma a explicar a maior parte da variabilidade e sem perda substancial da informação. PCA é utilizado para a redução da dimensionalidade sem considerar a correlação entre a variável dependente e a independente, enquanto PLS explora esta correlação.

Na literatura pesquisada não foi encontrado um estudo sobre o comportamento espectral do feijoeiro infectado com mofo-branco utilizando reflectâncias hiper e

multiespectral, de forma a quantificar a severidade da doença. É necessário, primeiramente, testar a hipótese de que a resposta espectral do feijoeiro sobre o dossel pode indicar a presença de mofo-branco em estádios anterior ao de maturação (R9). Neste sentido, a determinação de comprimentos de onda, faixas espectrais, e também, o emprego destas informações em modelos como índices de vegetação, podem melhorar a estimativa da severidade do mofo-branco. Considerando que informações de reflectância do feijoeiro infectado podem originar-se de sensores hiper e multiespectral, torna-se importante a comparação entre estes sistemas, visto que, imagens multiespectrais obtidas, por exemplo, de plataforma orbital, tem a vantagem do baixo custo, revisita programada e grande cobertura de área. Este estudo objetivou identificar comprimentos de onda e faixas espectrais provenientes de reflectâncias hiper e multiespectrais, utilizando regressão PLS; e, promover avaliação comparativa destes métodos e de índices de vegetação citados na literatura, para determinar aqueles que melhor estimam níveis de severidade de mofo-branco em feijão.

## **MATERIAL E MÉTODOS**

### **Condução dos experimentos**

Os experimentos utilizados foram cedidos pela Empresa de Pesquisa Agropecuária de Minas Gerais – Epamig, sendo conduzidos em duas áreas com histórico de ocorrência de mofo-branco: 1) Campo experimental Diogo Alves de Melo, em Viçosa, MG / Universidade Federal de Viçosa (UFV), com coordenadas geográficas de 20°45'S e 42°52'W, altitude de 648m; 2) Fazenda Experimental do Vale do Piranga / Epamig, Oratórios, MG, com coordenadas de 20°24'S e 42°48'W, altitude de 450m. Os experimentos foram nomeados como UFV e FEVP com as datas de plantio em 05/05/2011 e 18/05/2011, respectivamente. A irrigação foi por aspersão convencional, e o sistema de plantio, convencional, em que o preparo do solo foi realizado por grade aradora. Para o controle de plantas invasoras, foram realizadas capinas manuais. A aplicação de inseticidas foi feita quando necessária para controle de pragas. Na adubação de plantio, foi empregada a formulação

comercial 8-28-16 de N-P<sub>2</sub>O<sub>5</sub>-K<sub>2</sub>O. Após a emergência, os feijoeiros receberam aplicação de solução de molibdênio na folhagem.

A parcela experimental foi composta por seis linhas de 3 m, espaçadas de 0,5 m, sendo a área útil as quatro fileiras centrais. Os tratamentos foram arranjados no esquema fatorial 4x2x2: densidades de plantas (4, 7, 10 e 13 plantas.m<sup>-1</sup>), genótipos de feijão de porte ereto do tipo II (CNFC 10720 e VC 6) e tratamentos com o fungicida fluazinam (com ou sem aplicação), totalizando 16 tratamentos. O delineamento foi o de blocos ao acaso, com 4 repetições. As interações do esquema fatorial foram utilizadas para atender os objetivos de pesquisa da Epamig, sendo considerado neste estudo como método para proporcionar diferentes níveis de severidade de doença. O fluazinam foi aplicado na dose de 0,65 L.ha<sup>-1</sup> no início da floração e 10 dias depois, utilizando pulverizador tipo costal de CO<sub>2</sub>. O controle de doenças foliares foi feito antes da floração, com a azoxistrobina com doses de 60 g.ha<sup>-1</sup>.

#### **Aquisição de dados em campo**

As plantas de cada parcela foram avaliadas individualmente usando uma escala de notas de 0 a 4 (HALL e PHILLIPS, 1996), em que 0 = planta sadia; 1 = 1% a 25% da planta com sintoma de mofo-branco; 2 = 26% a 50% da planta com sintoma; 3 = 51% a 75% da planta com sintoma, e 4 = acima de 76% da planta com sintoma. O índice de severidade de doença (ISD) no estágio fenológico R9 (maturação das plantas), em cada parcela, foi calculado com base na equação de VIEIRA et al. (2010):

$$\text{ISD} = \frac{\sum (\text{nota atribuída a cada planta})}{4 \times (\text{total de plantas avaliadas})} \times 100 \quad (1)$$

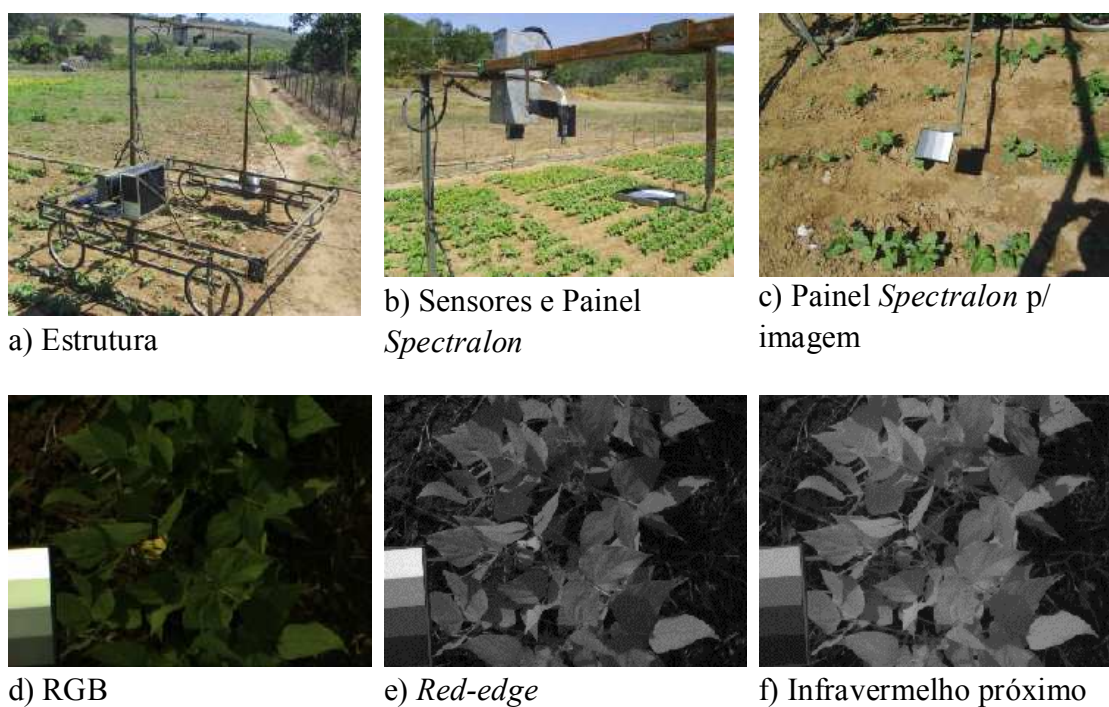
A aquisição das reflectâncias e de imagens foi realizada semanalmente, entre 10:00 e 14:00 horas (horário local de Brasília), para minimizar a influência na geometria de iluminação (ângulos de zênite e de azimute do sol). Todas as medidas foram feitas com céu aberto. Foram obtidas três tomadas de leitura de reflectância e de imagem por parcela de forma a abranger somente as linhas úteis (sem bordadura).

As medidas foram obtidas no terço inferior, médio e superior da parcela, obedecendo o sentido de maior comprimento.

Para medidas de reflectâncias hiperespectrais, utilizou-se o espectroradiômetro ASD FieldSpec HandHeld2 (Analytic Spectral Devices, Boulder, EUA), com campo de visão do sensor óptico de 25°, instalado a uma altura de 3 m, compreendendo uma área de cobertura de 1,39 m<sup>2</sup> sobre o solo. A faixa útil de leitura adotada foi entre 440 e 900 nm de forma a descartar os dados espectrais ruidosos nos extremos. Operações de otimização e calibração de reflectância (aquisição de referência de branco padrão) foram realizadas a cada 20 minutos, utilizando painel de referência branca *Spectralon* (Labsphere, North Sutton, USA). Cada ponto adquirido de reflectância correspondeu a uma média de 10 varreduras feita pelo sensor, referente ao mesmo alvo. O processamento com os dados brutos de reflectância foram feitas com o software ViewSpecproc (Analytic Spectral Devices, Boulder, EUA). Foi obtida a média das três leituras de reflectância de forma a representar a medida da parcela.

As imagens multiespectrais foram adquiridas por meio da câmara modelo FD-1665-MS5 (Fluxdata, Incorporated, New York, USA) com três CCDs. Um dos CCDs é colorido e contém três bandas: vermelha-R, verde-G e azul-B. Os outros CCDs são monocromáticos: um para a banda *Red-edge* e outro para o Infravermelho próximo (IV). A resolução média das imagens foi de 1280 x 960 pixels, com resolução espacial média de 0,35 mm.pixels<sup>-1</sup>. Para a calibração de cada imagem, utilizou-se painel *Spectralon*, modelo SRT-MS-050 (Labsphere, North Sutton, USA), composto de quatro tons de cinza: branco difuso, cinza claro, cinza médio e cinza escuro, com reflectâncias de 99, 50, 25 e 12%, respectivamente (Figura 1).

Para aquisição dos dados de espectrometria do dossel e das imagens multiespectrais, foi utilizada uma plataforma com quatro rodados e articulações que permitiam variar o tamanho da bitola (Figura 1a), possibilitando ajustar o equipamento à largura da parcela. O suporte da fibra óptica (ligada ao espectroradiômetro) e da câmara multiespectral foram acoplados a uma estrutura de altura de três metros do solo. O suporte da fibra óptica e a câmara digital foram direcionadas a nadir (Figura 1b). Os painéis *Spectralon* foram adaptados à estrutura em sistema retrátil de forma a permitir seu posicionamento dentro do campo de visão do espectroradiômetro (Figura 1b) e da câmera (Figura 1c).



**Figura 1.** Estrutura para aquisição de reflectâncias, sensores, painéis *spectralon* e amostras de imagem multiespectral.

A partir da imagem obtida com dossel e painel *Spectralon* (Figura 1) foi estabelecido cinco equações de calibração (uma para cada banda) para a transformação do valor do pixel de cada banda em reflectância. Os pontos utilizados para definir a equação em cada banda foram obtidos de amostras feitas em cada tom de cinza da placa apresentada na respectiva imagem. As equações foram definidas pelo ajuste de uma equação de regressão linear simples entre os valores de pixels amostrados no painel de cada imagem e os valores de reflectância de cada tom de cinza do painel fornecidos pelo fabricante, conforme Equação 2:

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 P \quad (2)$$

em que:

$\hat{Y}$  = valor estimado de reflectância para uma dada banda;

$\hat{\beta}_0$  = constante de regressão;

$\hat{\beta}_1$  = coeficiente da regressão;

P = valor de pixel na imagem original para uma dada banda.

Após a transformação do valor do pixel para reflectância, calculou-se a média dos valores de pixel utilizando as três imagens obtidas na parcela. Assim, cada parcela foi definida por cinco valores reais médios, uma para cada banda.

As imagens e as medidas de espectrometria foram feitas até o início do estágio R9 para evitar medidas de necrose por maturação.

### **Identificação de comprimentos de onda hiperespectrais e bandas multiespectrais por regressão PLS**

A regressão PLS foi aplicada aos dados de espectrometria e de reflectâncias médias obtidas das cinco imagens multiespectrais. Objetivou-se identificar os comprimentos de onda e ou bandas mais importantes para criar um modelo preditivo da doença. A regressão PLS, de forma simplificada, pode ser explicada pelo uso de técnicas de componentes principais que usa da decomposição espectral de uma matriz de variáveis dependentes (Y) em seus *scores* (U) e *loadings* (Q). De igual modo, uma matriz de variáveis independentes (X) decomposta em função de seus *scores* (T) e *loadings* (P), tal que, há uma relação entre os *scores* T e U, onde se pode determinar um coeficiente angular  $b$  ( $\tan \alpha$ ) entre os eixos (Equação 3 e 4).

$$b = U'T/T'T \quad (3)$$

A variável dependente a ser predita ( $Y_p$ ) é dada por:

$$Y_p = TbQ' + \varepsilon \quad (4)$$

em que,  $\varepsilon$  = vetor de resíduos.

Inicialmente, foi feita a checagem da presença de valores atípicos (*outliers*). Utilizou-se da estatística de z-score robusto (DASZYKOWSKI et al., 2007) o qual identifica medidas anômalas a partir de resíduos entre valores medidos e preditos, obtidos com o uso da regressão PLS em todo o conjunto de dados (Equação 5).

$$\left| \frac{e_i - \text{mediana}\{e_i\}_{i=1}^n}{Q_n} \right| > C \quad (5)$$

em que,  $e_i$ : i-ésimo resíduo;  $C$ : limite de corte dada a distribuição normal (3 vezes o desvio padrão);  $n$ : número de observações;  $Q_n$ : estimador de escala (Equação 6).

$$Q_n(y_1, \dots, y_n) = 2,2219 \{ |y_i - y_j|; 1 \leq i < j \leq n \}_{(k)} \quad (6)$$

onde,  $k = 0,5 \cdot h(h - 1)$ ;  $h = \left( \left\lceil \frac{n}{2} \right\rceil + 1 \right)$ ;

em que;  $k$  corresponde a ordem estatística indicando o maior valor de  $Q_n$  calculado em função da diferença entre resíduos ( $y_i - y_j$ ).

Os dados utilizados na regressão PLS foram pré-processados pela técnica de centrar na média, visto ser o método indicado para informações de espectrometria (FERREIRA et al.,1999), dado pela Equação 7.

$$x_c = x - \mu(x) \quad (7)$$

em que,  $x$ : valor do componente na coluna;  $\mu(x)$ : média do componente na coluna.

Posteriormente, para cada DAE de tomada da reflectância, foi estabelecido a divisão das informações aleatória em dois grupos, calibração e validação, com 70% e 30% das observações, respectivamente. Após esta ação, foi estabelecida a correlação entre as reflectâncias em todos os comprimentos de onda e a severidade da doença, utilizando o grupo de calibração. Os valores absolutos desta correlação foram ordenados na ordem decrescentes. A partir das correlações ordenadas foram construídos subgrupos de variáveis independentes, onde o primeiro subgrupo correspondeu ao comprimento de onda de melhor correlação, e os subgrupos subsequentes foram formados pelo subgrupo anterior mais o comprimento de onda de maior correlação que ainda não pertencia a nenhum subgrupo. Assim, o último subgrupo a ser formado tinha todos os comprimentos de ondas. Cada subgrupo foi submetido à regressão PLS e cálculos de correlação foram determinados entre os valores medidos e previstos.

A definição dos comprimentos de onda selecionados pela regressão PLS foi em função de uma medida de qualidade do modelo ( $q$ ), determinada pela razão entre a correlação e a Raiz do Erro Quadrático Médio (RMSE) normalizado. O RMSE é dado conforme Equação 8:

$$RMSE = \sqrt{\frac{\sum_1^n (y_i - \hat{y}_i)^2}{n}} \quad (8)$$

em que:  $n$  é o número de amostras;  $y_i$  é valor real da variável dependente e  $\hat{y}_i$  o valor estimado pelo modelo de regressão.

Para determinação do RMSE no grupo de calibração, usou-se a validação cruzada deixando um de fora (*leave-one-out*). Este processo calibra os modelos da regressão PLS iterativamente usando todos os dados, exceto um. Em cada iteração, uma amostra diferente é deixada de fora a partir dos dados até que cada amostra seja

deixada de fora uma vez. Os valores das amostras deixadas de fora da calibração são então estimados e os resíduos de previsão computados.

Os comprimentos de onda selecionados foram aqueles que constituíram o modelo com a melhor medida de qualidade  $q$ . Este processo de seleção de comprimentos de onda foi baseado do trabalho de TEÓFILO et al. (2009).

Após definido o modelo pela regressão PLS, este foi utilizado nas observações do subgrupo de validação. Foi então calculado as correlações entre os valores medidos e estimados de forma a quantificar a significância do modelo para o subgrupo de validação.

### Índices de vegetação

Foram calculados onze índices de vegetação comuns à espectrometria hiperespectral e imagem multiespectral para posterior comparação na estimativa da severidade das doenças fúngicas. As Tabelas 1 e 2 apresentam, respectivamente, as equações para os índices de vegetação multi- e hiperespectrais.

**Tabela 1.** Índices de vegetação para uso em imagens multiespectrais

Índices <sup>1</sup>	Banda multiespectral <sup>2</sup>	Referência
DVI	IR - R	TUCKER (1979)
GNDVI	$(IR - G)/(IR + G)$	GITELSON et al. (1996)
MCARI	$[(RE - R) - 0,2(RE - G)] RE/R$	DAUGHTRY et al. (2000)
MCARI2	$\frac{1,5[2,5(IR - R) - 1,3(IR - G)]}{\sqrt{(2IR + 1)^2 - (6IR - 5\sqrt{R}) - 0,5}}$	HABOUDANE et al. (2004)
MSAVI	$0,5 \left[ 2(IR + 1) - \sqrt{[(2IR + 1)^2 - 8(IR - R)]} \right]$	QI et al. (1994)
NDVI	$(IR - R)/(IR + R)$	ROUSE et al. (1973)
OSAVI	$(IR - R)/(IR + R + 0,16)$	RONDEAUX et

		al. (1996)
RDVI	$\sqrt{\text{NDVI} \cdot \text{DVI}}$	ROUJEAN e BREON (1995)
TCARI	$3[(RE - R) - 0,2(RE - G) RE/R]$	HABOUDANE et al. (2002)
MCARI/OSAVI		ZARCO-TEJADA et al. (2004)
TCARI/OSAVI		HABOUDANE et al. (2002)

1) Índices de vegetação - DVI: Difference Vegetation Index; GNDVI: Green Normalized Difference Vegetation Index; MCARI: Modified Chlorophyll Absorption in Reflectance Index; MSAVI: Modified Soil Adjusted Vegetation Index; NDVI: Normalized Difference Vegetation Index; OSAVI: Optimized Soil Adjusted Vegetation Index; RDVI: Relative Difference Vegetation Index; TCARI: Transformed Chlorophyll Absorption Reflectance Index.

2) Banda multiespectral - R: reflectância no vermelho; G: reflectância no verde; RE: reflectância no *red-edge*; IR: reflectância no infravermelho próximo.

**Tabela 2.** Índices de vegetação para reflectâncias hiperespectrais

Índices <sup>1</sup>	Comprimento de onda hiperespectral <sup>2</sup>	Referência
DVI	$R_{800} - R_{680}$	TUCKER (1979)
GNDVI	$(R_{801} - R_{55}) / (R_{800} + R_{55})$	DAUGHTRY et al. (2000)
MCARI	$[(R_{700} - R_{670}) - 0,2(R_{700} - R_{55})] R_{700} / R_{670}$	DAUGHTRY et al. (2000)
MCARI2	$\frac{1,5[2,5(R_{800} - R_{670}) - 1,3(R_{800} - R_{55})]}{\sqrt{(2R_{800} + 1)^2 - (6R_{800} - 5\sqrt{R_{670}} - 0,5)}}$	HABOUDANE et al. (2004)
MSAVI	$0,5 \left[ (2R_{800} + 1) - \sqrt{[(2R_{800} + 1)^2 - 8(R_{800} - R_{670})]} \right]$	QI et al. (1994)
NDVI	$(R_{800} - R_{670}) / (R_{800} + R_{670})$	ROUSE et al.

		(1973)
OSAVI	$1,16(R_{800} - R_{670}) / (R_{800} + R_{670} + 0,16)$	RONDEAUX et al. (1996)
RDVI	$\sqrt{NDVI \cdot DVI}$	ROUJEAN e BREON (1995)
TCARI	$3[(R_{700} - R_{670}) - 0,2(R_{700} - R_{550})R_{700} / R_{670}]$	HABOUDANE et al. (2002)
MCARI/OSAVI		ZARCO-TEJADA et al. (2004)
TCARI/OSAVI		HABOUDANE et al. (2002)

1) Índices de vegetação-DVI: Difference Vegetation Index; GNDVI: Green Normalized Difference Vegetation Index; MCARI: Modified Chlorophyll Absorption in Reflectance Index; MSAVI: Modified Soil Adjusted Vegetation Index; NDVI: Normalized Difference Vegetation Index; OSAVI: Optimized Soil Adjusted Vegetation Index; RDVI: Relative Difference Vegetation Index; TCARI: Transformed Chlorophyll Absorption Reflectance Index;

2) Banda multiespectral -  $R_x$ : reflectância no comprimento de onda x.

## Softwares

Os métodos utilizados foram desenvolvidos em Matlab R12.1 (MathWorks, Natick, USA). Para a regressão PLS, utilizou-se o pacote OPS Toolbox para Matlab (TEÓFILO et al., 2009). Os algoritmos de regressão PLS adotados no pacote OPS Toolbox foram o SIMPLS (JONG, 1993) e Fast Kernel PLS (DAYAL e MacGREGOR, 1997). A rotina Matlab referente ao desvio  $\sigma_{Qn}$  foi obtida do sistema *Toolbox for Multivariate Calibration Techniques – TOMCAT* (DASZYKOWSKI et al., 2007).

## RESULTADOS

Os índices de severidade da doença para o mofo-branco nos dois experimentos foram baixos. Em muitas parcelas não houve presença da doença. Em Viçosa, a média foi de 5,8% e a mediana foi de 2,4%. Em Oratórios, a média foi de 7,4% e a mediana foi de 2,1%. As parcelas que apresentaram ISD menor que 3% foram de 53% em UFV e de 70% em FEVP.

A significância das correlações para os grupos de calibração e validação, reflectâncias hiper e multiespectrais (Tabela 3), demonstraram um melhor desempenho da regressão PLS para as reflectâncias hiperespectrais em relação às multiespectrais. Isto porque, a significância estatística para o grupo de calibração e para o de validação, em uma mesma DAE, ocorreu em maior número de datas para as reflectâncias de comprimentos de onda hiperespectral. Nas reflectâncias hiperespectrais, apenas o experimento UFV com 34 DAE não obteve significância mútua entre os grupos de calibração e validação. Nas regressões de bandas multiespectrais, houve uma única situação de correlações significativas mútuas entre os conjuntos de calibração e validação, no caso, experimento UFV, aos 96 DAE.

**Tabela 3.** Correlação entre índice de severidade de doença (ISD) medido e previsto pela regressão PLS considerando os grupos de calibração e de validação e reflectâncias hiper- e multiespectral.

Correlações <sup>(1)</sup>					
Exp.	DAE	Hiperespectral		Multispectral	
		Calibração	Validação	Calibração	Validação
FEVP	25	0,360 *	0,722 **	-0,002 <sup>ns</sup>	-0,517 <sup>ns</sup>
	52	0,713 ***	0,658 **	0,033 <sup>ns</sup>	0,359 <sup>ns</sup>
	60	0,569 ***	0,612 **	0,446 **	0,292 <sup>ns</sup>
	76	0,512 ***	0,544 *	-0,131 <sup>ns</sup>	-0,165 <sup>ns</sup>

	82	0,537 <sup>***</sup>	0,551 <sup>*</sup>	0,095 <sup>ns</sup>	0,032 <sup>ns</sup>
UFV	34	0,651 <sup>***</sup>	0,371 <sup>ns</sup>	0,464 <sup>**</sup>	0,184 <sup>ns</sup>
	62	0,418 <sup>**</sup>	0,478 <sup>*</sup>	-0,067 <sup>ns</sup>	0,238 <sup>ns</sup>
	69	0,580 <sup>***</sup>	0,681 <sup>**</sup>	0,258 <sup>ns</sup>	-0,041 <sup>ns</sup>
	83	0,591 <sup>***</sup>	0,684 <sup>**</sup>	-0,508 <sup>**</sup>	-0,113 <sup>ns</sup>
	96	0,685 <sup>***</sup>	0,672 <sup>**</sup>	0,349 <sup>*</sup>	0,563 <sup>*</sup>

<sup>(1)</sup>Nível de significância: \* p<=0.05; \*\* p<=0.01; \*\*\* p<0.001; ns=não significativo. Valor absoluto de correlação não-significativa maior que outra correlação significativa é em função dos graus de liberdade; Exp.: experimento; DAE: dias após emergência.

Os comprimentos de onda relativos aos modelos que constituíram significância estatística mútua para os conjuntos de calibração e de validação (Tabela 3), reflectância hiperespectral, estão listados na Tabela 4. Esta tabela demonstra que a faixa espectral do *red-edge* (690-730 nm) foi a mais representativa, pois esteve presente em todos os DAE. A quantidade e relação dos comprimentos de onda selecionados pela regressão PLS variaram durante o ciclo da cultura nos experimentos FEVP e UFV. Houve períodos em que o melhor grupo definido pela regressão PLS foi constituído por todos os comprimentos de onda medidos (461 valores), como no experimento FEVP aos 25 DAE.

**Tabela 4** –Grupo de comprimentos de onda selecionados por regressão PLS

Exp.	DAE	NCO	Intervalos de comprimentos de onda
FEVP	25	461	440-900
	52	300	526-566;631-691;703-900
	60	206	503-503;508-512;515-593;596-598;600-601;695-810

	76	248	467-467;485-488;550-550;553-554;646-686;702-900
	82	239	440-441;492-701;715-732;889-897
UFV	62	190	537-541;543-557;706-813;828-889
	69	67	707-763;891-900
	83	134	514-611;694-729
	96	338	440-501;528-559;640-641;647-697;710-900

Exp.: experimento; DAE: dias após emergência; NCO: número de comprimentos de onda selecionados na regressão PLS.

Entre os índices de vegetação para reflectâncias hiper e multiespectral (Tabela 5), observa-se também um maior número de correlações significativas para os índices hiperespectrais em relação aos multiespectrais, quando se compara a quantidade de datas que apresentaram significância estatística. Em hiperespectral, todas as correlações foram significativas à excessão do experimento FEVP com 41 DAE. Entre estas correlações significativas, todas foram positivas, com exceção do experimento UFV com 96 DAE.

**Tabela 5**– Índices de vegetação (IV) que apresentam maior correlação com índice de severidade de doença (ISD) para reflectâncias hiper e multiespectral

Exp.	DAE	Hiperespectral		Multiespectral	
		IV	r <sup>(1)</sup>	IV	r <sup>(1)</sup>
FEVP	25	TCARI/OSAVI	0,326*	-	-0,253ns
	41	-	0,249 <sup>ns</sup>	GNDVI	0,321*
	52	TCARI/OSAVI	0,447***	-	0,252 <sup>ns</sup>
	60	TCARI/OSAVI	0,532***	-	0,198 <sup>ns</sup>

	76	MCARI	0,407**	-	0,070 <sup>ns</sup>
UFV	34	TCARI/OSAVI	0,394**	MCARI	0,503***
	49	MCARI/OSAVI	0,513***	-	0,235 <sup>ns</sup>
	62	MCARI/OSAVI	0,414**	MCARI	0,290*
	69	MCARI/OSAVI	0,534***	MCARI	0,473***
	83	TCARI/OSAVI	0,517***	-	0,119 <sup>ns</sup>
	96	DVI	-0,503***	GNDVI	-0,472***

<sup>(1)</sup> Nível de significância: \*  $p \leq 0,05$ ; \*\*  $p \leq 0,01$ ; \*\*\*  $p < 0,001$ ; ns=não significativo  
Exp.: experimento; DAE: dias após emergência; IV: índice de vegetação; r: correlação.

MCARI: Modified Chlorophyll Absorption in Reflectance Index; TCARI: Transformed Chlorophyll Absorption Reflectance Index; OSAVI: Optimized Soil Adjusted Vegetation Index; DVI: Difference Vegetation Index; GNDVI: Green Normalized Difference Vegetation

## DISCUSSÃO

Os resultados demonstraram que os sistemas hiperespectrais foram mais eficientes em estimar a severidade da doença do que os multiespectrais. Sistemas hiperespectrais, ao proporcionarem um espectro contínuo devido a uma resolução espectral melhor do que os sistemas multiespectrais, são mais confiáveis e sensíveis na estimativa de características biofísicas de culturas (MIAO et al., 2009; THENKABAIL et al., 2000). Bandas multiespectrais utilizam valores médios da informação espectral, resultando na perda crítica de informação que está disponível em faixas estreitas específicas.

As variações ocorridas na quantidade e na relação dos comprimentos de onda selecionados pela regressão PLS podem estar ligadas à variações climáticas ocorridas no decorrer do experimento e que não foram mensuradas. Por exemplo, nos dados da

estação climatológica do Instituto Nacional de Metrologia (INMET), situada no campus da UFV, observou-se que no período correspondente ao experimento houve uma variação na temperatura média diária do ar entre 12,4 a 20,3°C; e, para umidade relativa do ar, uma variação entre 64,6 a 90,0%. Estas variações climáticas podem alterar a fisiologia da planta, e provocar variações de reflectância. SIMS e GAMON (2002) mencionam a influência das baixas temperaturas no conteúdo elevado de antocianina em folhas jovens. PONZONI e SHIMABUKURO (2009) relatam o aumento da reflectância em folhas de milho à medida que diminui o conteúdo de umidade nas folhas. CANTERI et al. (2010), mencionam que a intensidade do MB aumenta em função de temperaturas moderadas e períodos prolongados de alta umidade.

A maior representatividade da faixa espectral do *red-edge*, entre os comprimentos de onda descritos na Tabela 4, pode ser justificada pelo fato de que os patógenos causam uma redução do teor de clorofila na planta devido à necrose ou lesões cloróticas que afetam a reflectância na região espectral do *red-edge* e na região do visível (FRANKE e MENZ, 2007). As mudanças de reflectância em comprimentos de onda na faixa do vermelho (630-685 nm), dada a presença de doenças, fazem com que a transição brusca no espectro da região do visível para o infravermelho venha a se deslocar para comprimentos de onda mais curtos, tornando-se a faixa do *red-edge* um indicador eficiente de estresses em plantas (SHAFRI e HAMDAN, 2009; WEST et al., 2003).

Os índices da família CARI (TCARI e MCARI) e sua razão com OSAVI, bem como, o DVI, foram os mais representativos para identificação do mofo-branco (Tabela 5). A obtenção das leituras de reflectância do dossel foi realizada em diferentes estádios fenológicos e em diferentes níveis de severidade de doença, apresentando diferentes percentuais de cobertura do solo. Neste cenário, a reflectância do fundo de solo, a concentração de clorofila e o Índice de Área Foliar (IAF) interagem-se e constituem a reflectância do dossel (DAUGHTRY et al., 2000). Os índices MCARI e TCARI aqui indicados foram idealizados para serem sensíveis à variação de clorofila e resistentes a efeitos da reflectância de solo e de matérias não fotossintéticas, em especial a baixos valores de IAF (HOBOUDANE et al., 2002). O OSAVI e o DVI são índices que também minimizam o efeito do solo (RONDEAUX et al., 1996; ROUJEAN, 1995). Assim, a razão entre MCARI e TCARI com OSAVI

combinam as respectivas habilidades de cada um de forma a responder às variações da clorofila, minimizando os efeitos de IAF e de reflectância de fundo de solo (WU et al. 2008; ZARCO-TEJADA et al. 2004; HABOUDANE et al., 2002). Por outro lado, índice como o NDVI, comum na identificação da vegetação, é extremamente sensível às propriedades ópticas do solo, sendo difícil de ser interpretado com baixa cobertura vegetal (RONDEAUX, 1996). O NDVI é também sensível a grandes coberturas de vegetação, visto o problema de saturação que ocorre neste modelo para estas situações (GITELSON et al., 1996). Foi então observado neste trabalho que índices de vegetação que consideram a reflectância do solo estimam melhor as doenças de feijão do que os demais índices. CAO et al. (2013) apresentaram resultados similares a este, no caso, a correlação significativa de DVI e Soil-Adjusted Vegetation Index (SAVI) com índice de severidade de doença do trigo em diferentes estádios fenológicos; enquanto NDVI não foi significativo.

O maior número de correlações significativas apresentadas na Tabela 5 justifica-se, principalmente, em função de duas situações ocorridas durante o experimento: 1) houve pouca presença da doença nos experimentos; 2) A doença foi notada apenas nos estádios finais da cultura, no caso, mais que 75 DAE (estádios R8 e R9), segundo análise visual das plantas no local. Assim, considerando que durante a maior parte dos períodos as medidas de reflectâncias foram sob condições de poucos sintomas da doença, é tido que os índices de vegetação com correlações positivas estariam representando uma maior concentração de teor de pigmentos por unidade de área de cultivo. Caso contrário, em condição de maior severidade da doença, ocorreria uma menor concentração de pigmentos, gerando assim a expectativa de correlação negativa com os índices de vegetação. BLACKBURN (1998) relata que na maioria dos casos, todos os pigmentos, incluindo clorofila e carotenoide, estão linearmente relacionados ao IAF. Já maiores IAF estão relacionados com a maior interceptação da radiação fotossinteticamente ativa e consequente aumento da atividade fotossintética e da produção de matéria seca por planta (STRIEDER et al., 2008). Estas informações podem explicar o fato de que o mofo-branco inicia-se geralmente em reboleiras na lavoura, principalmente nos locais de alta densidade e acamamento de plantas, tornando-se mais destrutiva onde ocorre abundante crescimento vegetativo (PAULA JUNIOR et al. 2012, 2010; PAULA JUNIOR e ZAMBOLIM, 2006).

Por outro lado, a correlação significativa e negativa dada pelo índice DVI e Green-NDVI, hiper e multiespectral, respectivamente, apresentadas na Tabela 5, experimento UFV com 96 DAE, pode ser justificada pela fenologia na planta em fim de ciclo, caracterizada pela clorose, necrose e queda de folhas. As alterações nos valores de reflectância do visível e infravermelho, proporcionadas pela doença e senescência, promovem a diminuição da diferença entre as reflectâncias do red-edge e o vermelho, no caso do DVI e entre red-edge e verde em Green-NDVI. Esta diminuição da diferença é então inversamente correlacionada com o aumento da doença ou com a degradação foliar.

As correlações significativas apresentadas nas Tabelas 4 e 5 informam que mesmo em períodos anterior ao surgimento da doença há possibilidade de sua estimativa. Isto demonstra o potencial da metodologia empregada em determinar épocas e locais de maior susceptibilidade ao desenvolvimento da doença. Os comprimentos de onda e faixas espectrais com significância estatística apresentados nas Tabelas 4 e 5 poderiam ser utilizados na construção de plataformas de visão artificial para uso em máquinas agrícolas visando a estimativa da severidade da doença, e, para a definição de locais específicos para a aplicação de defensivos agrícolas. Entre os métodos utilizados, os modelos constituídos a partir de comprimentos de onda selecionados e os índices de vegetação, ambos para reflectâncias hiperespectrais, demonstraram ser eficientes. No caso do primeiro, este não apresentou um intervalo comum de comprimentos de onda considerando todas as datas juntas, o que poderia ser a influência de condições climáticas sobre dossel. Há, então, a necessidade de levantamento de variáveis climáticas dentro do dossel de forma a melhorar a compreensão do comportamento espectral da cultura durante seu ciclo, e assim, estabelecer modelos de maior acurácia. Quanto aos índices de vegetação para reflectâncias hiperepectral, estes tenderam a se repetir durante as datas, sendo representados pela razão entre os da família CARI com OSAVI. Esta tendência é positiva pois demonstra uma menor influência de parâmetros climáticos na estimativa da doença. No entanto, estes índices devem ser testados em condições de maior incidência de doença visando testar o seu desempenho nestas condições.

## CONCLUSÃO

Os métodos utilizados nesse estudo mostraram que as alterações de reflectância no feijoeiro provocadas pela ação do mofo-branco podem indicar a presença da doença a partir do último estágio vegetativo da cultura (V4), ainda que a severidade da doença seja pouca. Através dos métodos utilizados foi possível indicar épocas e locais de presença da doença antes que ela viesse a ocorrer. Estes locais podem ser interpretado como locais de maior suscetibilidade à manifestação da doença.

Modelos matemáticos a partir de comprimentos de onda selecionados por regressão PLS e por índices de vegetação, utilizando reflectâncias hiperespectrais, obtiveram melhor desempenho para a estimativa do mofo-branco no feijoeiro do que os modelos utilizando reflectâncias multiespectrais. Assim, os sistemas hiperespectrais, dada sua resolução espectral mais fina, foram considerados mais sensíveis e informativos na estimativa dos níveis de severidade das doenças em diversos estádios fenológicos.

Índices de vegetação que são resistentes a efeitos da reflectância de solo estimaram melhor as doenças de feijão do que os demais. Destacou-se o uso de índices da família CARI (TCARI e MCARI) e sua razão com OSAVI. Estes índices estão correlacionados ao mofo-branco de forma positiva e significativa na maior parte dos estádios fenológicos, utilizando reflectâncias hiperespectrais.

Quanto aos comprimentos de onda selecionados pela regressão PLS, a faixa espectral do *red-edge* foi a mais representativa, pois os comprimentos de onda selecionados para esta faixa estiveram presentes em todas as datas em que foram feitas as medidas de reflectância.

## BIBLIOGRAFIA

AHAMED, T.; TIAN, L.; ZHANG, Y.; TING, K. C. A review of remote sensing methods for biomass feedstock production. **Biomass and Bioenergy**, v. 35, n. 7, p. 2455–2469, 2011.

BARTON, C. V. M. Advances in remote sensing of plant stress. **Plant and Soil**, v. 354, n. 1-2, p. 41-44, 2011.

BLACKBURN, G. A. Hyperspectral remote sensing of plant pigments. **Journal of Experimental Botany**, v.58, p.844-867, 2007.

BLACKBURN, G. A. Quantifying chlorophylls and carotenoids at leaf and canopy scales: An evaluation of some hyperspectral approaches. **Remote Sensing of Environment**, v. 66, p. 273-285, 1998.

CANTERI, M. G.; SILVA, O. C. da; TSUKAHARA, R, Y. In: Pria, M. D.; Silva, O. C. (Ed.). **Cultura do Feijão: doenças e controle**. Ponta Grossa: UEPG, 2010.p.133-148.

CAO, X.; LUO, Y.; ZHOU, Y.; DUAN, X.; CHENG, D. Detection of powdery mildew in two winter wheat cultivars using canopy hyperspectral reflectance. **Crop Protection**, v. 45, p. 124-131, 2013.

DASZYKOWSKI, M.; SERNEELS, S.; KACZMAREK, K.; et al. TOMCAT: A MATLAB toolbox for multivariate calibration techniques. **Chemometrics and Intelligent Laboratory Systems**, v. 85, n. 2, p. 269–277, 2007.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; COLSTOUN, E. B. DE. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance **Remote sensing of environment**. v. 74, n. 2, p. 229-239, 2000.

DAYAL, B. S.; MacGREGOR, J. F. Improved PLS algorithms. **Journal of Chemometrics**, v. 11, p. 73-85, 1997.

DEVADAS, R.; LAMB, D. W.; SIMPFENDORFER, S.; BACKHOUSE, D. Evaluating ten spectral vegetation indices for identifying rust infection in individual wheat leaves. **Precision Agriculture**, v. 10, n. 6, p. 459–470, 2008.

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

FERREIRA, M. M. C. et al. Quimiometria I: calibração multivariada , um tutorial. **Química Nova**, v.22, n.5, p. 1-14, 1999.

FRANKE, J.; MENZ, G. Multi-temporal wheat disease detection by multi-spectral remote sensing. **Precision Agriculture**, v. 8, n. 3, p. 161-172, 2007.

GITELSON, A. A.; KAUFMAN, Y. J.; 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.

HABOUDANE, D. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, v. 90, p. 337-352, 2004.

HABOUDANE, D.; MILLER, J. R.; TREMBLAY, N.; ZARCO-TEJADA, P. J.; DEXTRAZE, L. Integrated narrow-band vegetation indices for prediction of crop

chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v. 81, p. 416-426, 2002.

HALL, R.; PHILLIPS, L. G. **Evaluation of parameters to assess resistance of white bean to white mold**. Annual Report of the Bean Improvement Cooperative. v. 39, p. 306-307. 1996.

HUANG, W.; LAMB, D. W.; NIU, Z. et al. Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging. **Precision Agriculture**, v. 8, n. 4-5, p. 187-197, 2007.

JONG, S. de. SIMPLS: An alternative approach to partial least squares regression. **Chemometrics and Intelligent Laboratory Systems**, v. 18, n. 3, p. 251-263, 1993.

JORDAN, C. F. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. **Ecological Society of America**. v. 50, n. 4, p. 663-666, 1969.

MAHLEIN, A. K. et al. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. **Precision Agriculture**, v. 11, n. 4, p. 413-431, 2010.

MIAO, Y.; MULLA, D. J.; RANDALL, G. W.; VETSCH, J. A.; VINTILA, R. Combining chlorophyll meter readings and high spatial resolution remote sensing images for in-season site-specific nitrogen management of corn. **Precision Agriculture**, v. 10, n. 1, p. 45-62, 2008.

PAULA JÚNIOR, T. J.; TEIXEIRA H.; VIEIRA R.F. **Laudo técnico de eficiência da aplicação de fungos antagonistas no controle de mofo-branco (sclerotinias clerotiorum) na cultura do feijão**. Viçosa, MG:EPAMIG: Viçosa, 2009.

PAULA JÚNIOR, T. J.; VIEIRA R. F.; LOBO JÚNIOR, M. et al. Mofo-Branco. In: Pria, M. D.; Silva, O. C. (Ed.). **Cultura do Feijão: doenças e controle**. Ponta Grossa: UEPG, 2010.p.133-148.

PAULA JÚNIOR, T. J.; VIEIRA R.F. TEIXEIRA H.; et al. Mofo-branco. In: PAULA JÚNIOR, T. J.; WENDLAND, A. (Eds.) **Melhoramento genético do feijoeiro-comum e prevenção de doenças**. Viçosa, MG: EPAMIG, 2012. 157p.

PAULA JÚNIOR, T. J.; ZAMBOLIM, L. Doenças. In: VIEIRA, C., PAULA JÚNIOR, T. J. e BORÉM, A. (Eds.) **Feijão**. Viçosa: Editora UFV. 2006. cap. 13, p. 359-414.

PINTER, et al. Remote sensing for crop management. **Photogrammetric Engineering and Remote Sensing**, v.69, p.647-664, 2003.

PONZONI, F. J.; SHIMABUKURO, Y. E. Sensoriamento Remoto no Estudo da Vegetação. São Jose dos Campos, SP: Ed. Parêntese, 2009. 135p.

PRABHAKAR, M.; PRASAD, Y. G.; DESAI, S. et al. Hyperspectral remote sensing of yellow mosaic severity and associated pigment losses in Vigna mungo using multinomial logistic regression models. **Crop Protection**, v. 45, p. 132-140, 2013.

- QI, J.; CHEHBOUNI, A.; HUETE, A. R.; KERR, Y. H.; SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v. 48, n. 2, p. 119-126, 1994.
- RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of Soil-Adjusted Vegetation Indices. **Remote Sensing of Environment**. v. 55, n. 2, p. 95-107, 1996.
- ROUJEAN, J.; BREON, F. Estimating PAR Absorbed by Vegetation from Bidirectional Reflectance Measurements. **Remote Sensing of Environment**, v. 51, n. 3, p. 375-384, 1995.
- ROUSE, J. W.; HASS, R. H., SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: Earth Resources Technology Satellite (ERTS) Symposium, 3, 1973, Washington, DC. **Proceedings...** Washington, DC: NASA, 1973. v. 1, p. 309-317.
- SHAFRI, H. Z. M.; HAMDAN N. Hyperspectral Imagery for Mapping Disease Infection in Oil Palm Plantation Using Vegetation Indices and Red Edge Techniques. **American Journal of Applied Sciences**. v. 6, n. 6, p. 1031-1035, 2009.
- SIMS, D. A; GAMON, J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, v. 81, n. 2-3, p. 337-354, 2002.
- SONG, S. et al. Wavelength selection and spectral discrimination for paddy rice, with laboratory measurements of hyperspectral leaf reflectance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 5, p. 672-682, 2011.
- STRIEDER, M. L.; SILVA, P. R. F. DA; RAMBO, L. et al. Características de dossel e rendimento de milho em diferentes espaçamentos e sistemas de manejo. **Pesquisa Agropecuária Brasileira**, v. 43, n. 3, p. 309-317, 2008.
- TEÓFILO, R. F.; MARTINS, J. P. A.; FERREIRA, M. M. C. Sorting variables by using informative vectors as a strategy for feature selection in multivariate regression. **Journal of Chemometrics**, v. 23, n. 1, p. 32-48, 2009.
- THENKABAIL, P. S.; SMITH, R. B.; PAUW, E. DE. Hyperspectral Vegetation Indices and Their Relationships with Agricultural Crop Characteristics. **Remote Sensing of Environment**, v. 71, p. 158-182, 2000.
- TUCKER, C. J. Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. **Remote sensing of environment**. v. 150, n. 8, p. 127-150, 1979.
- VIEIRA, R. F.; JÚNIOR, T. J. P.; TEIXEIRA, H. et al. White Mold Management in Common Bean by Increasing Within-Row Distance Between Plants. **Plant Disease**, v. 94, n. 3, p. 361-367, mar. 2010.
- WEST, J. S.; BRAVO, C.; OBERTI, R. et al. The potential of optical canopy measurement for targeted control of field crop diseases. **Annual review of phytopathology**, v. 41, p. 593-614, 2003.

WU, C.; NIU, Z.; TANG, Q.; HUANG, W. Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. **Agricultural and Forest Meteorology**, v. 148, n. 8-9, p. 1230-1241, 2008.

ZARCO-TEJADA, P.; MILLER, J.; MORALES, A; BERJÓN, A; AGÜERA, J. Hyperspectral indices and model simulation for chlorophyll estimation in open-canopy tree crops. **Remote Sensing of Environment**, v. 90, n. 4, p. 463-476, 2004.

## CAPÍTULO 3

---

### DETECÇÃO MULTI-TEMPORAL DE MOFO-BRANCO DE FEIJÃO UTILIZANDO REFLECTÂNCIAS HIPERESPECTRAL FOLIAR

### MULTI-TEMPORAL DETECTION OF COMMON BEAN WHITE MOLD USING LEAF HYPERSPECTRAL REFLECTANCE

#### RESUMO

Este estudo objetivou identificar comprimentos de onda com base em reflectâncias hiperespectrais foliar, visando a estimativa da severidade do mofo-branco em cultivos de feijão para diferentes datas, utilizando regressão PLS. Experimentos foram implantados nos municípios de Viçosa e de Oratórios, estado de Minas Gerais, em períodos de outono / inverno. Para determinação dos comprimentos de onda que melhor representam a severidade da doença, regressão PLS foi aplicado a subgrupos destes comprimentos de onda em diferentes datas. Medidas de erro e de correlação entre valores medidos e preditos foram utilizados para estabelecer os comprimentos de onda que melhor estimam a doença nas diferentes datas. Faixas espectrais de transição entre as bandas azul e verde e entre as bandas verde e vermelho e entre as bandas vermelho e infravermelho mostraram-se sensíveis à estimativa da doença. Os comprimentos de onda determinados para estas faixas de transição foram 522, 523, 573, 590, 692, 705, 710, 715, 718 nm. Além das faixas de transição, outras regiões espectrais também apresentaram comprimentos de onda com potencial para determinar a severidade da doença: 506 nm para o azul; 650, 651, 653 a 661 e 663 nm para o vermelho; 532, 533, 538 e 539 nm para o verde; e, para comprimentos de onda maior que 780 nm para o infravermelho próximo.

**Palavras chave:** *Sclerotinia sclerotiorum*, Regressão PLS, pigmentos, espectro, absorção.

## ABSTRACT

This study aimed to identify wavelengths based on hyperspectral leaf reflectance to estimate the white mold severity in common bean crops for different dates using PLS regression. Experiments were implemented in the municipalities of Viçosa and Oratorios, Minas Gerais state, in fall / winter periods. To find the best wavelengths to detect the disease severity, PLS regression was applied to subgroups of these wavelengths at different dates. Error measurements and correlation between measured and predicted values were used to establish the best wavelengths. The transition spectral ranges between blue and green bands and between green and red bands and between red and infrared bands demonstrated to be sensitive to the estimate of the disease. These transition wavelengths were 522, 523, 573, 590, 692, 705, 710, 715, 718 nm. Beyond the transition ranges, other spectral regions sections also presented wavelengths with potential to determine the severity disease: 504, 506 and 509 nm for blue; 650, 651, 653 to 661 and 663 nm for red; 532, 533, 538 e 539 nm for green; and wavelengths greater than 780 nm to near infrared wavelength.

**Keywords:** *Sclerotinia sclerotiorum*, PLS Regression, pigments, spectrum, absorption.

## INTRODUÇÃO

Em condições de alta umidade e temperaturas amenas, uma lavoura de feijão infectada com mofo-branco [*Sclerotinia sclerotiorum* (Lib.) de Bary] pode sofrer, em média, perdas de 30% ou mais, podendo chegar a 100 % em períodos chuvosos e quando medidas preventivas não são tomadas (OLIVEIRA, 2005). Por outro lado, o patógeno responsável pela doença impõe muitos desafios para o estabelecimento de práticas efetivas de manejo. Neste caso, o controle com fungicidas é possível, no entanto, o custo pode ser alto para muitos agricultores (PAULA JUNIOR, 2012). Uma alternativa de manejo pode ser o uso de sensoriamento remoto para a identificação de áreas afetadas por doenças de forma a permitir a aplicação de fungicidas a taxas variadas em locais específicos; e com a possibilidade de utilização

desta ação antes que a doença venha a se manifestar. Tais medidas podem reduzir o custo de produção e diminuir o impacto ambiental em função da menor quantidade de uso de fungicidas.

O mofo-branco é uma das doenças mais destrutivas do feijoeiro em áreas irrigadas do Brasil, notadamente nos plantios efetuados nas safras de outono-inverno. Nessa época, a baixa evapotranspiração e a alta umidade do solo proporcionada pela irrigação favorecem a doença, que geralmente é pouco prejudicial nas épocas tradicionais de cultivo (PAULA JÚNIOR et al., 2010).

Doenças em plantas podem causar alterações na taxa de transpiração, cor da folha, morfologia e densidade de cultivo, que por sua vez afetam as propriedades ópticas do dossel (WEST, 2003). Plantas infectadas por vírus, em especial, poderiam se manifestar em um ou muitos sintomas, tais como, alterações na pigmentação foliar, ondulação, murcha, nanismo, clorose, necrose ou amputação de partes da planta (PRABHAKAR et al., 2013). O sintoma inicial para o mofo-branco é geralmente a murcha da planta, sendo resultado do apodrecimento do caule. Depois, os sintomas que podem ocorrer nas folhas, hastes e vagens, se dão através da formação de manchas encharcadas, seguidas por crescimento de micélio branco e cotonoso, o que dá origem ao nome “mofo-branco” (PAULA JÚNIOR, 2010).

Um dos principais métodos utilizados para avaliar o estado nutricional do feijoeiro é a diagnose foliar. A planta funciona como extrator do nutriente do solo e a folha é o centro das atividades fisiológicas e, antes do florescimento, é o principal local para onde os nutrientes absorvidos pelas raízes são transportados (FERREIRA et al., 2004). Quando a luz atinge uma folha, uma parte do espectro da luz é refletida em direção ao observador. Esta reflexão é governada pelas propriedades na superfície da folha, a estrutura interna e a concentração e distribuição dos componentes bioquímicos no interior da folha (como nitrogênio, lignina, celulose). Assim, existe a informação de que a luz refletida está relacionada com as propriedades físicas e bioquímicas da folha (BARTON, 2012). Apesar de todos os componentes do dossel interagirem com a radiação eletromagnética, as folhas têm especial atenção, pois estão presentes durante a maior parte do ciclo da planta e possuem elevada superfície em relação aos demais componentes do dossel (VARELLA, 2010).

Propriedades de reflexão espectral com base na absorção de luz em comprimentos de onda específicos estão associadas com características específicas da planta. Para as culturas saudáveis, reflectância nos comprimentos de onda no visível (400-700 nm) é baixa por causa da elevada absorção por pigmentos fotoativos (clorofilas, antocianinas, carotenóides). Em contraste, a reflectância nos comprimentos de onda no infravermelho próximo (700-1300 nm) é alta devido ao espalhamento múltiplo nas interfaces de células de ar no tecido interno da folha (MAHLEIN et al., 2013; PRABHAKAR et al., 2013; YANG, 2010; PONZONI e SHIMABUKURO, 2009).

Assim, comprimentos de onda específicos podem fornecer informações úteis na interpretação utilizando monitoramento por sensoriamento remoto em culturas com estresses ambientais. Além disso, a técnica pode ser considerada como uma ferramenta valiosa para a seleção de um sensor apropriado para um problema em particular, ou mesmo para a concepção de um novo sensor (SONG et al., 2011). MAHLEIN et al. (2013) menciona que a avaliação da doença de plantas por meio de sensores podem ser específicos para: detecção (alteração da saúde), identificação (diferenciação entre várias doenças) e quantificação (medição da gravidade da doença e percentagem de área foliar afetada).

Sensoriamento remoto hiperespectral obtém dados de reflectância em uma ampla faixa espectral e com pequenos incrementos espectrais, normalmente abaixo de 10 nm, podendo resultar em variáveis redundantes e de complexidade computacional. Assim, a eliminação destas variáveis redundantes podem melhorar a robustez e precisão de um modelo. Seu sucesso depende do tamanho da amostra de treinamento, do número de componentes desejados e do tipo de dados espectrais para a qual são aplicados (SONG et al., 2011). Neste sentido, Regressão por Mínimos Quadrados Parciais (PLS) é uma técnica multivariada comumente usada, a qual é capaz de lidar com um grande número de variáveis ruidosas e correlacionadas, e com um pequeno número de observações (TEÓFILO et al., 2009). É um método versátil, utilizado para análise qualitativa e quantitativa, podendo ser utilizado para discernir a importância de comprimentos de onda para a previsão de doenças (SONG et al., 2011; ANDRIES et al., 2011; JONES et al., 2010).

Muitos agricultores contam atualmente com a percepção visual nos dosséis de suas culturas para a avaliação da presença ou do risco de doença. No entanto, tais avaliações, além de subjetivas, podem ser demoradas e imprecisas. O uso de medidas

de reflectância e índices espectrais podem trazer vantagens sobre metodologias convencionais de avaliação visual, tal como a utilização de bandas de frequência que vão além do limite de sensibilidade humana, a capacidade para detectar os primeiros sintomas antes do especialista e, o mais importante, a capacidade de co-analisarem relações complexas entre diversas propriedades (HUANG et al., 2007).

Este estudo teve por objetivo testar a hipótese de que reflectâncias hiperespectral foliar podem fazer detecção do mofo-branco em diversos estádios fenológicos, mesmo antes do surgimento dos primeiros sintomas visuais. Para isso, foi utilizada a técnica de regressão PLS de forma a indicar faixas espectrais e comprimentos de onda que constituam modelos multivariados de correlação significativa com a severidade do mofo-branco em diversas fases do ciclo da feijão.

## **MATERIAL E MÉTODOS**

### **Condução dos experimentos**

Os experimentos utilizados foram implantados pela Empresa de Pesquisa Agropecuária de Minas Gerais – Epamig, sendo compartilhado para o desenvolvimento desse trabalho de pesquisa. Foram conduzidos em duas áreas com histórico de ocorrência de mofo-branco: 1) Campo experimental Diogo Alves de Melo da Universidade Federal de Viçosa (UFV), em Viçosa, MG, com coordenadas geográficas de 20°45'S e 42°52'W, altitude de 648m; 2) Fazenda Experimental do Vale do Piranga da Empresa de Pesquisa Agropecuária de Minas Gerais (Epamig), em Oratórios, MG, com coordenadas de 20°24'S e 42°48'W, altitude de 450m. Os experimentos foram nomeados como UFV e FEVP, em que, as datas de plantio foram, respectivamente, 05/05 e 18/05/2011. Em todos os experimentos, a cultura foi mantida sob regime de irrigação por aspersão convencional, conduzidas em sistema de plantio convencional, onde o preparo do solo foi realizado por grade aradora. Para o controle de plantas invasoras, foram realizadas capinas manuais e, para controle de pragas, foram realizadas aplicações de inseticidas. Na adubação de plantio, foi empregada a formulação comercial 8-28-16 de N-P-K. Após a

emergência, os feijoeiros receberam aplicação de solução de molibdênio na folhagem.

A parcela experimental foi composta por seis linhas de 3 m, espaçadas de 0,5 m, sendo a área útil as quatro fileiras centrais. O delineamento foi o de blocos ao acaso, com 4 repetições. Os tratamentos foram arranjados no esquema fatorial 4x2x2: densidades de plantas (4, 7, 10 e 13 plantas.m<sup>-1</sup>), genótipos de feijão de porte ereto do tipo II (CNFC 10720 e VC 6) e tratamentos com o fungicida Fluazinam (com ou sem aplicação), totalizando 16 tratamentos. As interações do esquema fatorial foram utilizadas para atender os objetivos de pesquisa da Epamig, sendo considerado neste estudo como método para proporcionar diferentes níveis de severidade de doença. O Fluazinam foi aplicado no volume de 0,65 L.ha<sup>-1</sup> no início da floração e 10 dias depois, utilizando pulverizador tipo costal pressurizado com CO<sub>2</sub>. O controle de doenças foliares foi feito antes da floração, com composto de Azoxistrobina.

### **Determinação dos níveis de doença**

O índice de severidade de doença (ISD) para o mofo-branco foi realizado no estágio fenológico R9 (maturação das plantas). Para isso, as plantas de cada parcela foram avaliadas individualmente usando uma escala de notas de 0 a 4 (HALL e PHILLIPS, 1996), em que 0 = planta sadia; 1 = 1% a 25% das plantas com sintomas de mofo-branco; 2 = 26% a 50% das plantas com sintomas; 3 = 51% a 75% das plantas com sintomas, e 4 = acima de 76% da planta com sintomas. O ISD em cada parcela foi calculado com base na equação de VIEIRA et al. (2010), descrita conforme Equação 1.

$$\text{ISD} = \frac{\sum (\text{nota atribuída a cada planta})}{4 \times (\text{número de plantas avaliadas})} \times 100 \quad (1)$$

### **Aquisição de dados em campo**

Para leituras de reflectância, utilizou-se o espectrorradiômetro ASD FieldSpec HandHeld2 (Analytic Spectral Devices, Boulder, EUA), com campo de visão do sensor óptico de 25°, faixa espectral entre 350-1100 nm. A faixa útil de leitura adotada foi entre 400 e 1050 nm, descartando os dados espectrais ruidosos nos

extremos. Operações de otimização e calibração do aparelho foram realizadas antes da aquisição usando painel de referência branca “Spectralon” (Labsphere, North Sutton, USA). Cada ponto adquirido de reflectância correspondeu a uma média de 10 varreduras feita pelo sensor, referente ao mesmo alvo.

Para efetuar as leituras de reflectância junto às folhas, utilizou-se uma sonda de contato com fonte de luz própria tipo Halogênica, 6 watts de potência, com temperatura de cor de 2911+/-10 K. Os processos de calibração, utilizando o painel “Spectralon”, foram feitos em intervalos de 10 a 20 minutos. A lâmpada de halogênio foi pré-aquecida por 90 minutos antes das leituras visando aumentar a qualidade e homogeneidade dos dados espectrais (MANHALEN, 2010). O tempo de integração para conversão da luz recebida em acumulo de sinal elétrico foi de 138ms, determinado no processo de otimização. Nos experimentos, as reflectâncias foliares foram obtidas de 27 folhas em nove plantas distribuídas dentro da parcela, sendo que, para cada planta, mediu-se a reflectância em uma folha do terço superior, uma do terço médio e uma do terço inferior. O valor da reflectância foliar para a parcela foi definido pela média das 27 leituras.

As medidas de espectrometria foram feitas até o início do estágio R9 para evitar medidas de necrose por maturação.

### **Identificação de comprimentos de onda hiperespectrais por regressão PLS**

A definição dos comprimentos de onda mais importantes para estabelecer o modelo preditivo da severidade da doença foi feito com base em regressão PLS, utilizando 601 medidas de reflectância (variáveis explicativas). Regressão PLS foi utilizada nesta situação, não só pelo uso de múltiplas variáveis, como também, pelo fato de evitar efeitos negativos pela multicolinearidade e por evitar também o superajuste do modelo dado o número de observações ser menor que o número de variáveis (LIU et al., 2007).

A base para construção de modelos por regressão PLS é a Análise de Componentes Principais (PCA). De forma simplificada, pode ser explicada pelo uso de técnicas de componentes principais que usa a decomposição espectral de uma matriz de variáveis dependentes (Y) em seus *scores* (U) e *loadings* (Q). De igual modo, uma matriz de variáveis independentes (X) decomposta em função de seus

scores (T) e loadings (P), tal que, há uma relação entre os scores T e U, onde se pode determinar um coeficiente angular  $b$  ( $\tan \alpha$ ) entre os eixos, chamado também de coeficiente de regressão (Equação 2).

$$b = U'T/T'T \quad (2)$$

A variável dependente a ser predita ( $Y_p$ ) é dada conforme Equação 3.

$$Y_p = TbQ' + \varepsilon \quad (3)$$

em que,  $\varepsilon$  = vetor de resíduos.

Inicialmente, foi feita a checagem da presença de valores atípicos (*outliers*). Utilizou-se da estatística de z-score robusto (DASZYKOWSKI et al., 2007) o qual identifica medidas anômalas a partir de resíduos entre valores medidos e preditos, obtidos com o uso da regressão PLS em todo o conjunto de dados (Equação 4).

$$\left| \frac{e_i - \text{mediana}\{e_i\}_{i=1}^n}{Q_n} \right| > C \quad (4)$$

em que,  $e_i$ : i-ésimo resíduo;  $C$ : limite de corte dada a distribuição normal (3 vezes o desvio padrão);  $n$ : número de observações;  $Q_n$ : estimador de escala (Equação 5).

$$Q_n(y_1, \dots, y_n) = 2,2219 \{ |y_i - y_j|; 1 \leq i < j \leq n \}_{(k)} \quad (5)$$

$$\text{onde, } k = 0,5 \cdot h(h - 1); h = \left( \left\lceil \frac{n}{2} \right\rceil + 1 \right);$$

em que,  $k$  corresponde a ordem estatística indicando o maior valor de  $Q_n$  calculado em função da diferença entre resíduos ( $y_i - y_j$ ).

Os dados utilizados para a regressão PLS foram pré-processados pela técnica de centrar na média, visto ser o método indicado para informações de espectrometria (FERREIRA et al., 1999), dado pela Equação 6.

$$x_c = x - \mu(x) \quad (6)$$

em que,  $x$ : valor do componente na coluna;  $\mu(x)$ : média do componente na coluna.

Posteriormente, para cada DAE de tomada da reflectância, foi estabelecido a divisão das informações aleatória em dois grupos, calibração e validação, com 70% e 30% das observações, respectivamente. Após esta ação, foi estabelecida a correlação entre as reflectâncias em todos os comprimentos de onda e a severidade da doença, utilizando o grupo de calibração. Os valores absolutos desta correlação foram ordenados na forma decrescentes. A partir das correlações ordenadas foram construídos subgrupos de variáveis explicativas, onde o primeiro subgrupo correspondeu ao comprimento de onda de melhor correlação, e os subgrupos

subsequentes foram formados pelo subgrupo anterior mais o comprimento de onda de maior correlação que ainda não pertencia a nenhum subgrupo. Assim, o último subgrupo formado tinha todos os comprimentos de ondas utilizados. Cada subgrupo foi submetido à regressão PLS e cálculos de correlação foram determinados entre os valores medidos e previstos.

A utilização da regressão PLS em cada subgrupo gerou  $n$  componentes principais (variáveis latentes) que correspondem à viabilidade dos dados em seu formato original. O número de variáveis latentes utilizadas para definir a variabilidade de cada subgrupo foi em função da menor Raiz do Erro Quadrático Médio – RMSE (Equação 7).

$$RMSE = \sqrt{\frac{\sum_1^n (y_i - \hat{y}_i)^2}{n}} \quad (7)$$

em que:  $n$  é o número de amostras;  $y_i$  é o valor real da variável dependente e  $\hat{y}_i$  o valor estimado pelo modelo de regressão.

Para estimativa do RMSE, usou-se a se a validação cruzada deixando um de fora (*leave-one-out*). Este processo calibra os modelos PLS iterativamente usando todos os dados, exceto um. Em cada iteração, uma amostra diferente é deixada de fora a partir dos dados até que cada amostra seja deixada de fora uma vez. Os valores para as amostras deixadas de fora da calibração são então previstos e os resíduos de previsão calculados.

A definição dos comprimentos de onda selecionados pela regressão PLS foi em função de uma medida de qualidade ( $q$ ), determinada pela razão entre a correlação e o RMSE normalizado. Este processo de seleção de comprimentos de onda foi baseado do trabalho de TEÓFILO et al. (2009).

Após definido o modelo pela regressão PLS, este foi utilizado nas observações do subgrupo de validação. Foi então calculado as correlações entre os valores medidos e estimados de forma a quantificar a significância do modelo para o subgrupo de validação.

## **Softwares**

A estatística descritiva foi realizada pelo aplicativo Minitab Statistical Software (Minitab Inc., USA), versão 14. Os demais métodos utilizados foram desenvolvidos

em Matlab R12.1 (MathWorks, Natick, USA). O processamento dos dados brutos de reflectância foram feitos com o software ViewSpecproc (Analytic Spectral Devices, Boulder, EUA). Para a regressão PLS, utilizou-se o pacote OPS Toolbox para Matlab (TEÓFILO et al.; 2009). Os algoritmos de regressão PLS adotados no pacote OPS Toolbox foram o SIMPLS (JONG, 1993) e Fast Kernel PLS (DAYAL e MacGREGOR, 1997). A rotina Matlab referente ao desvio  $\sigma_{qn}$  e utilizada no calculo do z-score robusto foi obtida do sistema *Toolbox for Multivariate Calibration Techniques – TOMCAT* (DASZYKOWSKI et al., 2007).

## RESULTADOS

A estatística descritiva dos índices de severidade de doenças (ISD) do mofo-branco para os experimentos FEVP e UFV (Tabela 1) demonstra que a normalidade dos dados dos dois experimentos foi rejeitada pelo teste de Anderson-Darling (p-valor <0,005). Essa falta de normalidade na distribuição dos valores de ISD foi devida a grande concentração de valores pequenos de ISD, em especial, os iguais a zero, e a presença de outliers (observações atípicas) que estariam associados aos maiores valores de ISD. Assim, em ambos os experimentos houve baixa severidade da doença, sendo que as parcelas de maior ISD, os valores não chegaram a 46%.

**Tabela 1.** Estatística descritiva do índice de severidade de doença.

FEVP	UFV
Média: 7,44;	Média: 5,79;
Mediana: 2,12;	Mediana: 2,44;
Variância: 128,42	Variância: 63,38
Mín.: 0,00;	Mín.: 0,00;
Máx.: 45,45	Máx.: 32,08
Normalidade (p-valor): <0,005	Normalidade (p-valor): <0,005

Uma análise comparativa entre os valores RMSE provenientes da regressão PLS utilizando modelos com todos comprimentos de onda e modelos com comprimentos de onda selecionados (grupo calibração e validação) é apresentada na Tabela 2. São também descritos nesta tabela as correlações (r) e os respectivos graus de liberdade (GL) para os grupos de calibração e validação. Observa-se entre as datas de DAE que os valores de GL podem ser diferentes, o que se deve à presença de outliers que foram retirados. Em todos as datas de DAE, o RMSE dos comprimentos de onda selecionados, subgrupo de calibração, apresentam valores pouco menores quando comparados aos modelos utilizando todos os comprimentos de onda, demonstrando um melhor desempenho por este método.

**Tabela 2.** Parâmetros de correlação provenientes de regressão PLS para modelos utilizando comprimentos de onda selecionados e modelos com todos os comprimentos de onda.

Exp.	DAE	Comprimentos de onda selecionados						Todos compr. de onda RMSE
		Calibração			Validação			
		r	RMSE	GL	r	RMSE	GL	
FEVP	25	0,530 <sup>***</sup>	9,07	40	0,681 <sup>**</sup>	9,94	16	10,06
	41	0,372 <sup>*</sup>	5,36	42	0,041 <sup>ns</sup>	8,89	17	5,47
	52	0,552 <sup>***</sup>	9,25	42	0,314 <sup>ns</sup>	14,07	18	9,29
	60	0,510 <sup>***</sup>	7,70	43	0,477 <sup>*</sup>	8,01	18	7,92
	76	0,365 <sup>*</sup>	5,97	42	0,558 <sup>*</sup>	10,16	18	6,03
	82	0,349 <sup>*</sup>	5,35	42	0,153 <sup>ns</sup>	5,90	17	5,39
UFV	18	0,588 <sup>**</sup>	7,36	26	0,658 <sup>*</sup>	9,29	10	7,37
	34	0,553 <sup>***</sup>	5,29	42	0,477 <sup>*</sup>	5,39	17	5,63
	49	0,391 <sup>**</sup>	8,58	45	0,669 <sup>**</sup>	5,41	17	9,00
	62	0,746 <sup>***</sup>	4,02	40	0,563 <sup>*</sup>	5,41	17	5,32
	69	0,700 <sup>***</sup>	5,59	42	0,476 <sup>*</sup>	7,59	18	7,23
	83	0,692 <sup>***</sup>	4,06	41	0,741 <sup>***</sup>	4,16	17	4,11
96	0,509 <sup>***</sup>	5,95	42	0,687 <sup>**</sup>	5,73	18	6,07	

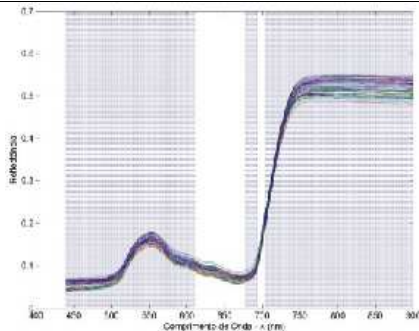
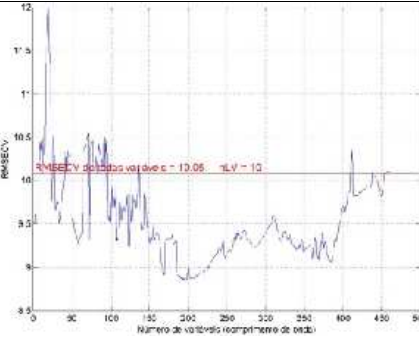
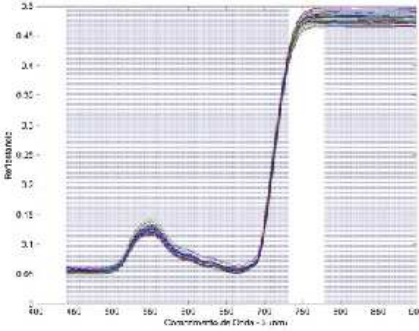
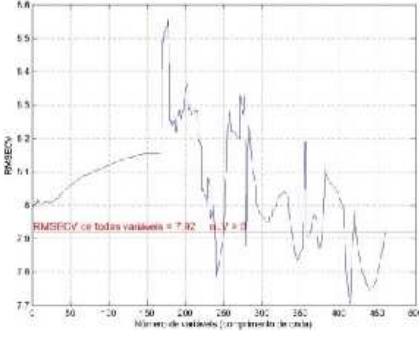
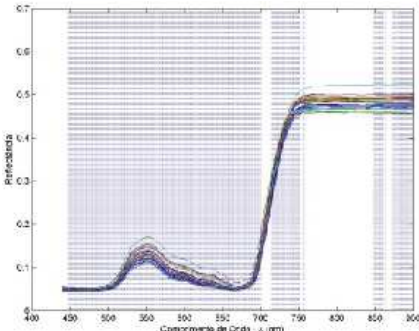
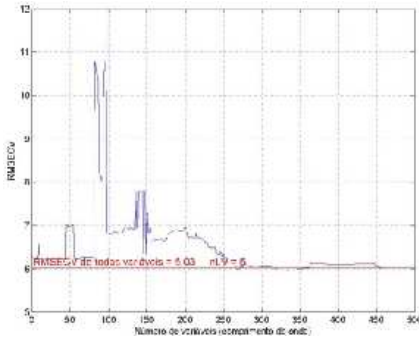
<sup>(1)</sup> Nível de significância: \* p<=0,05; \*\* p<=0,01; \*\*\* p<0,001; ns=não significativo.

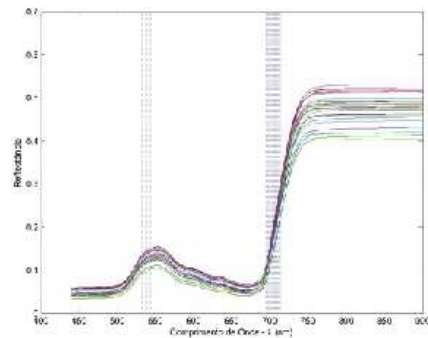
r: medida de correlação; RMSE: Erro Quadrático Médio; GL: graus de liberdade.

Para o experimento FEVP aos 52 DAE, o conjunto de calibração apresentou um coeficiente de correlação com alta significância (0,552), sendo que a respectiva correlação no grupo de validação (0,314) não foi significativa. Neste caso, mesmo com a aleatorização, poderia ter ocorrido uma concentração de amostras mais representativas no grupo de calibração. Tal fato foi igualmente observado na análise multitemporal de RYU et al. (2011).

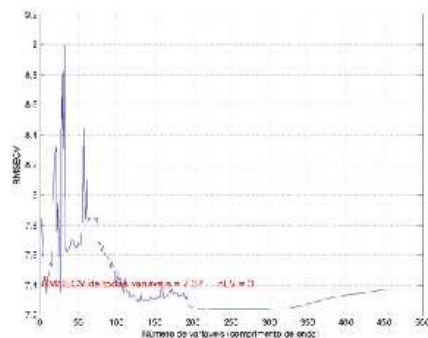
Gráficos relativos aos comprimentos de onda selecionados pela regressão PLS, bem como, a relação e a quantidade destes comprimentos de onda, estão apresentados na Tabela 3. Estas informações são relativas ao grupo de calibração apresentados na Tabela 2 em que ocorre significância simultânea nas regressões da calibração e da validação. A primeira coluna apresenta as curvas de reflectância espectral das folhas e os comprimentos de onda selecionados. A segunda coluna apresenta o valor do RMSE em função do número de comprimentos de onda testados em cada modelo. A linha horizontal presente nos gráficos da segunda coluna informa o RMSE e o número de variáveis latentes utilizadas no modelo, quando se utiliza todos os comprimentos de onda. Portanto, toda parte da curva que esteja abaixo desta linha representa a quantidade de comprimentos de onda que melhor estimam a severidade da doença em relação ao uso de todos os comprimentos de onda. A relação dos comprimentos de onda selecionados são apresentados na terceira coluna.

**Tabela 3.** Seleção de comprimentos de onda por regressão PLS em que ocorre correlação significativa nos grupos de calibração e de validação.


Curvas de reflectância e comprimentos de onda selecionados	RMSE vs. nº de comprimentos de onda	Comprimentos de onda selecionados
FEVP		
 <p data-bbox="459 891 571 927" style="text-align: center;">25 DAE</p>		<p>440-606; 608-610; 678-694; 704-900;</p>
 <p data-bbox="459 1317 571 1352" style="text-align: center;">60 DAE</p>		<p>440-732; 780-900;</p>
 <p data-bbox="459 1720 571 1756" style="text-align: center;">76 DAE</p>		<p>447-700; 715-751; 756-758; 849-861; 864-864; 873-900;</p>



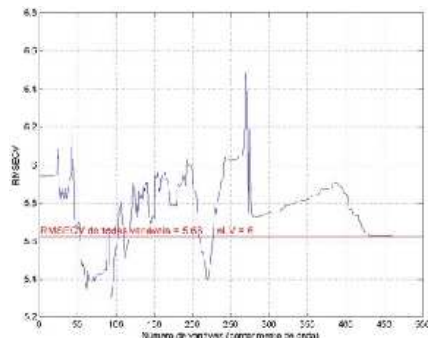
18 DAE




532-533; 538-539; 542-544; 695-714;




34 DAE




573-663; 691-692;



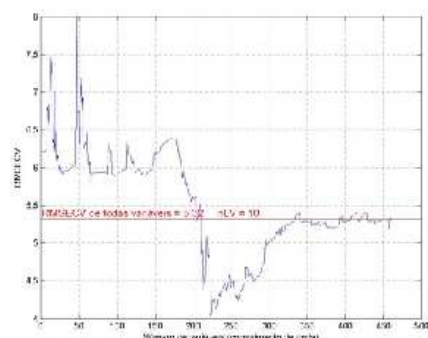
49 DAE




440-552; 556-563; 566-590; 593-632; 634-634; 645-646; 650-651; 653-670; 673-674; 676-678; 702-718; 736-753; 766-900



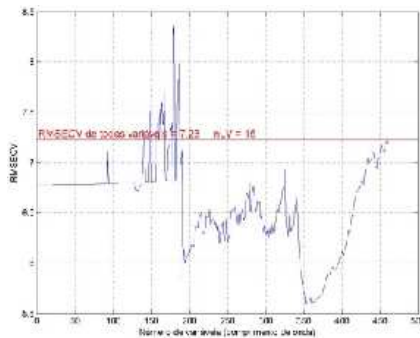
62 DAE




440-443; 464-464; 504-504; 506-506; 573-573; 649-723; 762-900;



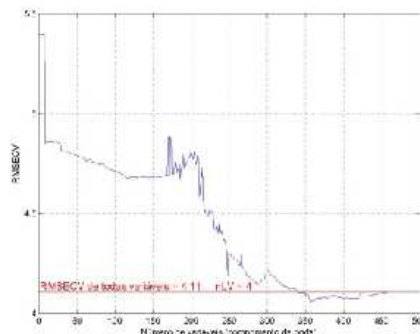
69 DAE



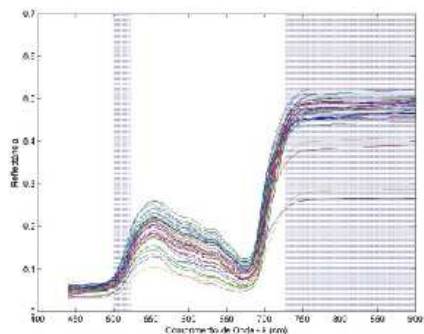
491-502; 505-661; 718-900;



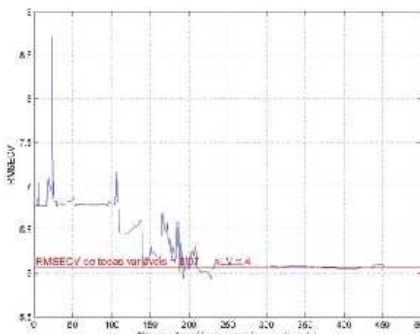
83 DAE



500-500; 522-523; 527-528; 533-534; 538-541; 545-725; 735-900;



96 DAE



501-510; 512-519; 521-523; 729-900;

Os comprimentos de onda considerados como mais representativos para a identificação da severidade da doença (Tabela 4) foram selecionados com base naqueles apresentados na Tabela 3 e determinados em função da frequência de sua utilização nos modelos e na magnitude dos seus coeficientes na regressão PLS. A frequência foi estabelecida a partir do número de vezes que cada comprimento de onda foi utilizado nos modelos. As duas maiores frequências de comprimentos de onda foram sete e oito vezes. O coeficiente de regressão PLS foi obtido do valor normalizado de  $b$  apresentado na Equação 4, indicando o comprimento de onda que

mais contribuiu para a determinação da doença, sendo que maior valor indica maior contribuição. Neste caso, os coeficientes de regressão podem ser positivos ou negativos. Na Tabela 4 é também apresentada a faixa espectral dos comprimentos de onda conforme nomenclatura em parênteses, dado por: azul-B (440-510 nm), verde-G (520-590 nm), vermelho-R (630-685 nm), *red-edge*-RE (690-730 nm) e infravermelho-IV (760-900 nm).

**Tabela 4.** Comprimentos de onda ( $\lambda$ ) de maior representatividade pela regressão PLS

Freq.	Comprim. de onda $\lambda$ (nm)	Maior coeficiente de Regressão PLS			
		FEVP		UFV	
		DAE	$\lambda$	DAE	$\lambda$
7	506 (B); 522-523, 533, 538-539, 574-590 (G), 593-606, 608-610 (G-R); 650-651, 653-661 (R); 718 (RE), 780-848, 862-863, 865-872 (IV)	25	504 <sup>(+)</sup> (B)	18	710 <sup>(+)</sup> (RE)
		60	532 <sup>(+)</sup> (G)	34	663 <sup>(+)</sup> (R)
		76	715 <sup>(+)</sup> (RE)	49	752 <sup>(+)</sup> (RE-IV)
				62	692 <sup>(-)</sup> (RE)
				69	509 <sup>(+)</sup> (B)
8	573 (G); 849-861, 864, 873-900 (IV)			83	705 <sup>(+)</sup> (RE)
				96	517 <sup>(-)</sup> (B-G)

## DISCUSSÃO

As curvas espectrais (Tabela 3) apresentaram, a exceção do experimento UFV aos 96 DAE, um comportamento espectral típico de vegetação verde e sem estresses, caracterizado por pontos bem definidos de absorção no azul e vermelho, reflectâncias do comprimento de onda central do verde de 0,15 a 0,20 (DAUGHTRY et al., 2000) e, no infravermelho próximo, reflectâncias próxima a 0,5 (KNIPLING, 1970). No

entanto, pequenas dispersões entre as curvas na faixa do visível e dispersões mais proeminentes no infravermelho próximo, principalmente no experimento UFV, estariam associadas à doença, mas com a manifestação tardia desta. Foi observado, visualmente, o surgimento do mofo-branco a partir de 47 DAE em FEVP e 78 DAE em UFV, correspondente aos estádios fenológicos R7 e R9, respectivamente. A severidade da doença também foi baixa, conforme apresentado na Tabela 1, onde a média do ISD nos dois experimentos não chegou a 8%. Quando o ISD é baixo, a resposta espectral da planta pode também ser pouco alterada. MAHLEIN et al. (2010) constataram que dez por cento de severidade entre folhas sadias e contaminadas por doenças fúngicas não foi significativo estatisticamente, e que, somente severidades de 20 a 50% podem ser detectadas com os valores mais elevados de reflectância na faixa espectral do visível.

Parte das alterações no comportamento espectral observado na Tabela 3 podem também ter sido influenciado por fatores externos, tais como, variações climáticas e volume hídrico utilizado na irrigação. PONZONI e SHIMABUKURO (2009) relatam, por exemplo, que a reflectância da folha pode aumentar ou diminuir pela quantidade de água na folha. Neste sentido, observa-se que as dispersões das curvas espectrais oscilam no decorrer das datas de leitura. No infravermelho próximo do experimento UFV, por exemplo, as dispersões entre as curvas são menores em 83 DAE do que nas datas anteriores, quando na verdade deveria ser o contrário, considerando a evolução da doença. Assim, nesta data ocorreriam maiores alterações nas reflectâncias sobre estresses de doenças, tal como, um aumento da reflectância na região do visível em função da diminuição na produção da clorofila (PRABHAKAR et al., 2013; MAHLEIN et al., 2013; WEST, 2003); e também, a diminuição da reflectância na região do infravermelho em função das alterações na estrutura interna (YANG, 2010; MALTHUS e MADEIRA, 1993; KNIPLING, 1970).

Apesar da pouca severidade de doença nos experimentos e da possível influência de dados externos nas reflectâncias, a regressão PLS possibilitou, conforme observado nas Tabelas 2, 3 e 4, determinar comprimentos de onda que constituíram modelos com significância estatística e que se repetiram no decorrer do ciclo, demonstrando assim que estas variáveis são sensíveis à presença da doença.

A Tabela 4 demonstra que a faixa espectral do infravermelho e do verde são os que possuem maior frequência entre os experimentos. No verde, comprimentos de

onda mais representativos são os de 573 nm (frequência de 8 vezes), juntamente com os comprimentos de onda de 522 a 523, 533, 538 a 539 e 574-590 (frequência de 7 vezes). Esta faixa é também representada pelo comprimento de onda de maior coeficiente de Regressão PLS, dado por 532 nm em FEVP 60 DAE. Nesta faixa espectral ocorre um aumento significativo na reflectância com a diminuição da concentração de clorofila (YANG, 2010). Outros comprimentos de onda estão presentes em regiões de transição do verde com faixas limítrofes, tal como, 593 a 606 e 608 a 610 nm (frequência de sete vezes) e 517 nm (maior coeficiente de frequência em UFV 96 DAE). Comprimentos de onda localizados nas faixas de transição tem sido destacados por alguns autores como importantes para estimativas de doenças ou de clorofila. Assim, comprimentos de onda entre o final da faixa do azul até 530 nm, e de 570 nm até o início do vermelho, correspondem a regiões de transição ou de mudanças entre áreas de absorção com áreas de maior reflexão. XUE e YANG (2009) definem a área transição entre azul e verde como borda-azul (*blue-edge*), semelhante a *red-edge*, que seria a inclinação máxima da curva de reflectância durante as faixas azul e verde (490-530 nm). Valores nas faixas de transição entre 520 a 530 nm e de 570 a 580 nm foram mencionados nos trabalhos de HUANG et al. (2012) e MALTHUS e MADEIRA (1993) como picos identificados pela primeira derivada de reflectâncias de folhas infectadas com doenças. Já BARTON (2012), mencionou o uso de comprimentos de onda pertencentes a este intervalo como aqueles utilizados no índice de vegetação PRI (Photochemical Reflectance Index), dado por:  $(531-570)/(531+570)$ , sendo que este índice é considerado útil para estimar a absorção de carotenóides de folhas (especialmente xantofila) e estresse de folha. O total de comprimentos de onda relacionados na Tabela 4 para o verde e faixas de transição é de quarenta. Destes, trinta e sete são menores que 530 e maiores que 570 nm, o que demonstra a importância destas faixas na determinação da severidade da doença.

MALTHUS e MADEIRA (1993) mencionam que, além dos comprimentos de onda presentes na faixa de transição do verde, aqueles presentes na transição do vermelho para o infravermelho (*red-edge*) são altamente correlacionados com níveis de infecção da doença de feijão estudada. Os comprimentos de onda relativos ao *red-edge* apresentados na Tabela 4 não são muitos em termos de frequência de aparecimento nos modelos. No entanto, o *red-edge* foi o comprimento de onda mais

presente entre os maiores coeficientes de regressão PLS. O *red-edge* corresponde à transição brusca que ocorre no espectro na região do visível para o infravermelho. As mudanças de reflectância em comprimentos de onda em torno de 670 nm (vermelho) faz com que o *red-edge* venha a se deslocar para comprimentos de onda mais curtos (WEST et al., 2003), tornando-se assim um bom indicador da presença de doença (SHAFRI e HAMDAN, 2009). Entre os comprimentos de onda de maior coeficiente de regressão, o de 692 nm aos 62 DAE, no experimento UFV, apresentou sinal negativo para *red-edge*, enquanto os demais são positivos. O *red-edge*, por ser uma região de transição entre a absorção do vermelho e a reflexão do infravermelho, funciona como um ponto de inflexão entre as duas regiões de comportamento espectral antagônico. Assim, no caso de estresse por doença, o coeficiente de correlação desta faixa pode estar demonstrando o aumento da reflectância do vermelho ou a diminuição da reflectância no infravermelho. O mesmo pode estar acontecendo na faixa de transição entre azul e verde.

A faixa espectral do vermelho foi a terceira mais representativa em números de bandas, atrás das faixas infravermelho e verde. Além dos comprimentos de onda presentes na faixa de transição entre verde e vermelho, o intervalo de 653 a 661 nm apresentou frequência igual a sete; e o comprimento de onda de 663 nm foi o de maior coeficiente de regressão PLS, aos 34 DAE no experimento UFV. Entre estes comprimentos de onda, os valores de 660, 661 e 663 nm estão dentro do limite de 660 a 680 nm citados por SIMS e GAMON (2002), que correspondem à absorção máxima na região do vermelho, sendo úteis para a previsão da quantidade de clorofila. A absorção da radiação ocorrida na faixa espectral do vermelho é feita somente pela clorofila. Assim, a presença de comprimentos de onda da faixa vermelho na correlação com a severidade da doença estaria ligada à diminuição dos pigmentos fotossintetizantes, em especial, a clorofila que é o pigmento predominante (60%) e o de principal influência na reflectância no espectro do visível (XUE e YANG, 2009; PONZONI e SHIMABUKURO, 2009). Os comprimentos de onda de 653 a 659 nm, mesmo que fora dos limites estabelecidos por SIMS e GAMON (2002), são adjacentes deste, formando assim um intervalo contíguo e podendo estar relacionado à clorofila e à severidade da doença.

O comprimento de onda do azul em 506 nm apresentou frequência de ocorrência de sete vezes. Esta faixa espectral também apresentou um representante com maior

coeficiente de regressão PLS, aos 69 DAE no experimento UFV. Por serem comprimentos de onda bem próximos, fica caracterizada uma faixa bem específica para absorção no azul para a caracterização do mofo-branco. No caso de associação de pigmentos à severidade da doença, deve-se estar ciente que a radiação presente na faixa espectral do azul é compartilhada entre clorofila e carotenoides (MAHLEIN et al. 2013; SIMS e GAMON, 2002).

O coeficiente de regressão negativo ocorrido no experimento UFV aos 96 DAE, comprimento de onda de 517 nm, pode estar relacionado ao mesmo efeito de transição discutido para o *red-edge*, relativo ao coeficiente de regressão de UFV 62 DAE. Outra justificativa seria que, as dispersões observadas nas diferentes faixas espectrais do experimento UFV, aos 96 DAE (Tabela 3), estariam mais relacionadas à senescência do que a severidade da doença. Com a senescência das folhas, diminui a quantidade de clorofila que influencia a resposta espectral nas faixas azul e vermelha, porém afetando em menor quantidade a faixa do azul visto que nesta faixa há a absorção compartilhada da energia entre a clorofila e os carotenoides. A Clorofila tende a diminuir mais rapidamente do que os carotenóides quando as plantas estão sob estresse ou durante a senescência foliar (GITELSON e MERZLYAK, 1994). Neste caso, a senescência estaria provocando um aumento das reflectâncias na faixa do visível. Porém, no comprimento de onda de 517 nm ocorreria a diminuição da reflectância (processo de absorção) à medida que aumenta a severidade da doença.

Os comprimentos de onda na faixa do infravermelho foram os que apresentaram maior frequência, seguido do verde, considerando os grupos de sete e oito repetições. Neste caso, estão relacionados todos os comprimentos de onda maior que 780 nm. A degradação na estrutura das folhas em função da doença levaria a uma diminuição do espalhamento interno da radiação eletromagnética e a um aumento na transmitância da folha na região do infravermelho próximo (YANG, 2010; MALTHUS e MADEIRA, 1993; KNIPLING, 1970). Assim, foi observado neste trabalho que as alterações espectrais do infravermelho, conjugadas à doença, ocorrem a partir do comprimento de onda de 780 nm e que corresponde ao patamar desta faixa na curva espectral. O intervalo entre 760 e 780 nm, que seria a curvatura ocorrida entre a inclinação do *red-edge* e o patamar, não se mostraram adequados para estimativa de mofo-branco. Esta faixa espectral não teve comprimento de onda que apresentou

maior coeficiente de regressão PLS para qualquer data de experimento. Desta maneira, comprimentos de onda isolados na faixa do visível e *red-edge* mostraram-se mais sensíveis à detecção do mofo-branco em comparação ao infravermelho próximo. Quando a doença ou outro estresse fisiológico afeta diretamente as propriedades de reflectância de folhas individuais, as mais pronunciadas alterações iniciais ocorrem frequentemente na região do espectro visível, devido à sensibilidade de clorofila a distúrbios fisiológicos (KNIPLING, 1970). Por outro lado, fazendo comparativo entre faixas espectrais, o infravermelho se mostrou sensível à estimativa da doença dada a repetitividade dos comprimentos de onda acima 780 nm durante o ciclo da cultura.

Este estudo demonstrou que comprimentos de onda e faixas espectrais relacionados em função da regressão PLS foram capazes de identificar o mofo-branco em diversos estádios fenológicos. A princípio, os comprimentos de onda identificados podem ser utilizados na concepção de sensores foliar para identificar o mofo-branco em diferentes etapas do ciclo da cultura. No entanto, este estudo poderá ter maior acurácia se tomadas de reflectâncias em campo forem feitas conjuntamente com anotações de clima e com quantificação de pigmentos da planta, visto que estas variáveis influenciam os valores da reflectância.

## CONCLUSÃO

A presença da doença apresentou modificações no comportamento espectral da folha em todas as faixas espectrais analisadas durante o ciclo da cultura. Assim, bandas espectrais e comprimentos de onda específicos podem ser utilizados para fazer a detecção do mofo-branco em diversos estádios fenológicos, mesmo antes dos primeiros sintomas da doença.

Entre os comprimentos de onda identificados, aqueles presentes em faixas de transição de absorção para reflexão mostraram-se sensíveis à estimativa da doença. Estas faixas de transição correspondem àquelas entre o azul e o verde (borda azul), entre o verde e o vermelho e entre o vermelho e o infravermelho, no caso, o *red-edge*. Na borda azul destacaram-se os comprimentos de onda, 522 e 523 nm. Na

faixa entre o verde e o vermelho, os comprimentos de onda de 573 a 590 nm. Já no *red-edge*, os valores 692, 705, 710, 715, 718 nm.

Além das faixas de transição, outras regiões também apresentaram comprimentos de ondas conjugadas significativamente à severidade da doença: 504, 506 e 509 nm para o azul; 532 a 533 e de 538 a 539 nm para o verde; e de 650 e 651, 653 a 661 e 663 nm para o vermelho. Os comprimentos de onda do vermelho estiveram localizados na parte central da região, informando que a severidade da doença esta relacionada a pontos de máxima absorção dentro desta faixa espectral. No infravermelho, os comprimentos que melhor representaram a severidade da doença estiveram localizados no patamar da curva de reflectância (maior que 780nm).

## **BILBIOGRAFIA**

ANDRIES, J. P. M.; VANDER HEYDEN, Y.; BUYDENS, L. M. C. Improved variable reduction in partial least squares modelling based on predictive-property-ranked variables and adaptation of partial least squares complexity. **Analytica chimica acta**, v. 705, n. 1-2, p. 292-305, 2011.

BARTON, C. V. M. Advances in remote sensing of plant stress. **Plant and Soil**, v. 354, n. 1-2, p. 41-44, 2012.

DASZYKOWSKI, M.; SERNEELS, S.; KACZMAREK, K.; et al. TOMCAT: A MATLAB toolbox for multivariate calibration techniques. **Chemometrics and Intelligent Laboratory Systems**, v. 85, n. 2, p. 269–277, 2007.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; COLSTOUN, E. B. DE. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance **Remote sensing of environment**. v. 74, n. 2, p. 229-239, 2000.

DAYAL, B. S.; MacGREGOR, J. F. IMPROVED PLS ALGORITHMS. **Journal of Chemometrics**, v. 11, p. 73-85, 1997.

FERREIRA, A. C. de B.; ANDRADE, M. J. B. de; ARAÚJO, G. A. de A. Nutrição e adubação do feijoeiro. **Informe Agropecuário**, Belo Horizonte, v. 25, n. 223, p. 61-72, 2004.

FERREIRA, M. M. C. et al. Quimiometria I: calibração multivariada , um tutorial. **Química Nova**, v.22, n.5, p. 1-14, 1999.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS. **Remote sensing of environment**. v. 58, n. 3, p. 289-298, 1996.

GITELSON, A. A.; MERZLYAK, M. N. Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* and *Acer platanoides*. Leaves-spectral features and relation to chlorophyll estimation. **Journal of Plant Physiology**. v.143, p.286–292, 1994.

HALL, R.; PHILLIPS, L. G. **Evaluation of parameters to assess resistance of white bean to white mold**. Annual Report of the Bean Improvement Cooperative. v. 39, p. 306-307. 1996.

HUANG, J.; LIAO, H.; ZHU, Y.; et al. Hyperspectral detection of rice damaged by rice leaf folder (*Cnaphalocrocis medinalis*). **Computers and Electronics in Agriculture**, v. 82, p. 100–107, 2012.

HUANG, W.; LAMB, D. W.; NIU, Z. et al. Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging. **Precision Agriculture**, v. 8, n. 4-5, p. 187-197, 2007.

JONES, C. D.; JONES, J. B.; LEE, W. S. Diagnosis of bacterial spot of tomato using spectral signatures. **Computers and Electronics in Agriculture**, v. 74, n. 2, p. 329-335, 2010.

JONG, S. de. SIMPLS: An alternative approach to partial least squares regression. **Chemometrics and Intelligent Laboratory Systems**, v. 18, n. 3, p. 251-263, 1993.

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.

LIU, Z.; HUANG, J.; SHI, J.; et al. Characterizing and estimating rice brown spot disease severity using stepwise regression, principal component regression and partial least-square regression. *Journal of Zhejiang University. Science. B*, v. 8, n. 10, p. 738–44, 2007.

MAHLEIN, A. K. et al. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. **Precision Agriculture**, v. 11, n. 4, p. 413-431, 2010.

MAHLEIN, A. K.; RUMPF, T.; WELKE, P. et al. Development of spectral indices for detecting and identifying plant diseases. **Remote Sensing of Environment**, v. 128, p. 21-30, 2013.

MALTHUS, T. J.; MADEIRA, A. C. High Resolution Spectroradiometry : Spectral Reflectance of Field Bean Leaves Infected by *Botrytis fabae*. **Remote Sensing of Environment**, n. 45, p. 107-116, 1993.

OLIVEIRA, S.H.F. Manejo do mofo branco. **DBO Agrotecnologia**, v.2, n.4, p.8-13, 2005.

PAULA JÚNIOR, T. J.; VIEIRA R. F.; LOBO JÚNIOR, M. et al. Mofo-Branco. In: Pria, M. D.; Silva, O. C. (Ed.). **Cultura do Feijão: doenças e controle**. Ponta Grossa: UEPG, 2010.p.133-148.

PAULA JÚNIOR, T. J.; VIEIRA R.F. TEIXEIRA H.; et al. Mofo-branco. In: PAULA JÚNIOR, T. J.; WENDLAND, A. (Eds.) **Melhoramento genético do feijoeiro-comum e prevenção de doenças**. Viçosa, MG: EPAMIG, 2012. 157p.

PONZONI, F. J.; SHIMABUKURO, Y. E. Sensoriamento Remoto no Estudo da Vegetação. São Jose dos Campos, SP: Ed. Parêntese, 2009. 135p.

PRABHAKAR, M.; PRASAD, Y. G.; DESAI, S. et al. Hyperspectral remote sensing of yellow mosaic severity and associated pigment losses in Vigna mungo using multinomial logistic regression models. **Crop Protection**, v. 45, p. 132-140, 2013.

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

SHAFRI, H. Z. M.; HAMDAN N. Hyperspectral Imagery for Mapping Disease Infection in Oil Palm Plantation Using Vegetation Indices and Red Edge Techniques. **American Journal of Applied Sciences**. v. 6, n. 6, p. 1031-1035, 2009.

SIMS, D. A; GAMON, J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, v. 81, n. 2-3, p. 337–354, 2002.

SONG, S. et al. Wavelength selection and spectral discrimination for paddy rice , with laboratory measurements of hyperspectral leaf reflectance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 5, p. 672-682, 2011.

TEÓFILO, R. F.; MARTINS, J. P. A.; FERREIRA, M. M. C. Sorting variables by using informative vectors as a strategy for feature selection in multivariate regression. **Journal of Chemometrics**, v. 23, n. 1, p. 32-48, 2009.

VARELLA, C. A. A; MEDEIROS R.; GLERIANI, J. M. Agricultura de Precisão e Sensoriamento Remoto. In: SANTOS, F.; BORÉM, A.; CALDAS, C (Eds.). **Cana-de-açúcar: bioenergia, açúcar e etanol: tecnologias e perspectiva**. Viçosa: Editora UFV. 2011. cap. 9, p. 245-269.

VIEIRA, R. F.; JÚNIOR, T. J. P.; TEIXEIRA, H. et al. White Mold Management in Common Bean by Increasing Within-Row Distance Between Plants. **Plant Disease**,v. 94, n. 3, p. 361-367, mar. 2010.

WEST, J. S.; BRAVO, C.; OBERTI, R. et al. The potential of optical canopy measurement for targeted control of field crop diseases. **Annual review of phytopathology**, v. 41, p. 593-614, 2003.

XUE, L.; YANG, L. ISPRS Journal of Photogrammetry and Remote Sensing Deriving leaf chlorophyll content of green-leafy vegetables from hyperspectral

reflectance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, n. 1, p. 97–106, 2009.

YANG, C. M.. Assessment of the severity of bacterial leaf blight in rice using canopy hyperspectral reflectance. **Precision Agriculture**, v.11, p.61-81, 2010.

## CONCLUSÕES FINAIS

O erro apresentado pelos modelos definidos pela regressão PLS foram menores utilizando comprimentos de onda selecionados quando comparados aos modelos utilizando todos os comprimentos de onda. A regressão PLS também apresentou melhores resultados para a estimativa da severidade das doenças estudadas quando comparada ao método de correlação e aos índices de vegetação. Assim, além da eficiência da regressão PLS em relação a outras técnicas, a utilização do método de seleção de comprimentos de onda permitiu maior robustez a este método de regressão, visto que foram determinados modelos menos complexos e com um menor uso de variáveis originais.

Em experimentos para mofo-branco, utilizando medidas de reflectância sobre dossel, foi observado que: modelos por regressão PLS e índices de vegetação com base em medidas hiperespectrais, apresentaram maior precisão do que os modelos obtidos de medidas multiespectrais, demonstrando que o espectro contínuo e de resolução espectral fina é mais sensível na estimativa de características biofísicas de culturas relacionadas à doença. O uso de índices de vegetação da família CARI (TCARI e MCARI) e sua razão com OSAVI, bem como, de DVI, foram os mais representativos para designo de mofo-branco. Os índices relacionados a família CARI e OSAVI são correlacionados significativamente ao mofo-branco de forma positiva e significativa na maior parte dos estádios fenológicos, utilizando reflectâncias hiperespectrais..

Com o aumento da severidade da mancha-angular no decorrer do ciclo da cultura, houve alterações no seu comportamento espectral, resultando em aumento da reflectância na faixa do visível e diminuição na faixa do infravermelho. No entanto, houve indicativo de que estas mudanças venham a ocorrer de forma mais contundente nos estádios finais da cultura, mais especificamente nos estádios fenológicos R8 e R9.

Os resultados indicam que as mudanças na resposta espectral, relacionados com a severidade da mancha-angular e do mofo-branco, são dependentes dos comprimentos de onda e sensíveis à gravidade da infestação. As faixas espectrais de maior representatividade na estimativa de doença, considerando mancha-angular e mofo-branco, foram o vermelho, *red-edge* e o infravermelho. Faixas espectrais em áreas de

transição de absorção para reflexão, também mostraram-se sensíveis à estimativa de mancha-angular (reflectâncias foliar e dossel) e mofo-branco para reflectâncias foliar. Estas faixas de transição correspondem àquelas entre o azul e o verde (borda azul) e entre o verde e o vermelho. A faixa espectral do azul foi mais frequente nas reflectâncias de dossel. Em mofo-branco, reflectância de dossel, há um número reduzido de comprimentos de onda no azul em comparação à mancha-angular, demonstrando que esta doença pode alterar mais os pigmentos que absorvem radiação nesta faixa do que o mofo-branco.

## ANEXOS

Aplicativos MATLAB desenvolvidos para a obtenção dos resultados utilizados neste estudo.

### a) Linearização e recorte de imagem

```
%% Processamento de Imagem
%
% troca background para negro e recorta imagem no limite das folhas
%
% Marley/UFV/DEA - Março/2012
%

%Seleção de pastas de trabalho
dir_in = uigetdir(cd,'Selecione uma pasta de entrada');
dir_out = uigetdir(dir_in,'Selecione uma pasta de saída');

%início do processamento

pasta=dir(fullfile(dir_in,'*.JPG'));
[nlinhas,c]=size(pasta);

for k=1:nlinhas
    arq0=fullfile(dir_in,pasta(k,1).name);
    arq1=fullfile(dir_out,strcat('r',pasta(k,1).name));
    disp(arq0);
    [I, map] = imread(arq0);
    t3= graythresh(I(:,:,3)); %banda 3:melhor para determ. o limiar
    bw3 = im2bw(I(:,:,3),t3);
    bw = bwareaopen(~bw3,10000,4);
    se = strel('disk',4);
    bw = imclose(bw,se); % imagem binária - mascara
    ind=find(bw==0);
    bw_=double(bw);
    bw_(ind)=NaN;
    I0(:,:,1)=double(I(:,:,1)).*bw_;
    I0(:,:,2)=double(I(:,:,2)).*bw_;
    I0(:,:,3)=double(I(:,:,3)).*bw_;

    %recorta extremos da figura
    [nl nc]=size(bw_);
    x=nc; X=0; y=nl; Y=0;
    for i=1:nc
        for j=1:nl
            if (bw(j,i)==1) %se obtiver informação
                x=min(x,i);
                X=max(X,i);
                y=min(y,j);
                Y=max(Y,j);
            end
        end
    end
end
end
```

```

    %grava anova imagem
    bw0=uint8(imcrop(I0, [x y X-x Y-y]));
    imwrite(bw0,arq1,'jpeg');
end

```

## b) Amostragem das classes nas folhas do feijão

```

% Aplicativo para amostrar pixels das folhas de feijão
%
% Marley/UFV/DEA - Fev/2012
%

%Seleção de pastas de trabalho
dir_in = uigetdir(cd,'Selecione uma pasta de entrada');
dir_out = uigetdir(dir_in,'Selecione uma pasta de saída');

numclasses=4; %informe o numero de classes
numamostras=50;
classes={'Folha Sadia','Necrose','Clorose','Morte Celular'};
continua='Sim';
while continua=='Sim'
    amostras = [];

    % abrir imagem no diretório
    [nome,caminho]= uigetfile(fullfile(dir_in,'*.jpg'),'Imagem');
    rgb = imread(strcat(caminho,nome));

    %configura janela
    set(0,'Units','pixels'); %ajusta unidade de tela para pixel
    scrsz = get(0,'ScreenSize'); %dimenssão de tela
    hFig = figure('Toolbar','none',... %atributos da figura
        'Menubar','none',...
        'Name','Amostragem',...
        'NumberTitle','off',...
        'IntegerHandle','off',...
        'Position',[scrsz(3)*0.01 scrsz(4)*0.05 ...
            scrsz(3)*0.99 scrsz(4)*0.90]);

    %processamento
    for j=1:numclasses
        resp='Sim';
        pos=[]; %coordenadas dos pixels
        if strcmp('Morte Celular',classes(j)) % pode não existir
            resp=questdlg('Esta imagem apresenta a classe "Morte ...
Celular?"','Amostragem',...
                'Sim','Não','default');
            if strcmp(resp,'Não')
                pos=ones(50,2)*-1.0; %caso não tenha, gera valor -1
            end
        end
        if strcmp(resp,'Sim')
            msgbox(strcat('Amostrar a Classe: ',classes(j)), ...
'modal');
            hIm = imshow(rgb);
            hSP = imscrollpanel(hFig,hIm); %barras de rolagem
            api = iptgetapi(hSP); %handle da figura
            api.setMagnification(1) % ampliação 2X = 200%

```

```

        % le coordenadas
        for i=1:numamostras
            hFH = impoint(); % faz leitura do pixel
            xy = getPosition(hFH); %obtem coordenada
            text(xy(1)+5,xy(2)+5,num2str(i)); % coordenada
            pos=[pos;xy]; %guarda as coordenadas
        end
    end
    amostras = [amostras pos];

end %for

%Gravando...
arq1=fullfile(dir_out, regexprep(nome, 'JPG', 'am'));
save(arq1,'amostras','-ASCII');

continua=questdlg('Continua?','Amostragem','Sim','Não','default');

end %While

```

### c) Seleção de amostras na forma aleatória

```

% Indices de vetor de amostras randômicas exclusivas
% Marley Lamounier Machado
% DEA/UFV/2012

% Parâmetros:
% nA: numero de amostras a serem escolhidas
% nElem: numero de Max de elementos

function indA = amostrarand(nA,nElem)
    S=zeros(1,nElem);
    RandStream.setDefaultStream ...
        (RandStream('mt19937ar','seed',sum(100*clock)));
    falta=1;
    while falta
        r=randi(nElem,1,nA);
        S(r)=max(S(r),1);
        indS=find(S==1);
        [l,c]=size(indS);
        if (c>=nA)
            falta=0;
        end
    end
    indA=indS(1,1:nA);
end %function

%
% Aplicativo para leitura de pixels das folhas de feijão
% a partir de pontos de coordenadas ja definidas e escolha de
% amostras de forma aleatória
%
% Marley/UFV/DEA - Mar/2012
%

```

```

% Estrutura do arquivo de saída:
%[Tipo_Imagem, CoordX, CoordY, Banda1, Banda2, Banda3, Classe,
%Tipo_Amostra]
% Tipo_Imagem: yCbCr (1),HSV(2), Lba(3),RGB(4)
% Tipo_amostra: Treinamento(1),Validação(0)

clc
clear

%Arquivos
dir_in = uigetdir(cd,'Selecione uma pasta de trabalho');
pasta=dir(fullfile(dir_in,'*.am'));
[narqs,c]=size(pasta);
lista = [];
t_imgs = {'yCbCr','HSV','Lba','RGB'};

for i=1:narqs

    disp(pasta(i,1).name);

    %lendo arquivos...
    arq1 = pasta(i,1).name;
    arq1=fullfile(dir_in, arq1); % arquivo .am -> amostra
    arq2= regexprep(arq1, '.am', '.amt');
    arqI= regexprep(arq1, '.am', '.JPG');

    %contraste das imagens
    newI=[];
    I=imread(arqI);
    for k=1:3
        mini=double(min(min(I(:,:,k))));
        maxi=double(max(max(I(:,:,k))));
        newI(:,:,k)=((double(I(:,:,k))-mini)/(maxi-mini)*255);
    end
    clear I;
    newI=uint8(newI);

    % lendo as amostras na forma original
    nmax=10; %numero maximo de amostras com morte celular
    amostras=load(arq1,'-ASCII');
    [nlinhas, ncols]=size(amostras);
    %nmax amostras de Necrose serão substituidas por Morte celular
    if sum(amostras(:,7)) > 0 %testa se existe ultima classe
        indA=amostrarand(nmax,nlinhas);
        for ii=1:nmax
            amostras(indA(ii),3)=amostras(indA(ii),7);
            amostras(indA(ii),4)=amostras(indA(ii),8);
        end
    end
    ncols=ncols-2;
    nclass=ncols/2;

    %Amostra todos tipos de imagem
    A=[];
    for nimg=1:4

        %atribuindo o tipo de imagem
        if strcmp(t_imgs(nimg),'yCbCr')

```

```

        IMG = rgb2ycbcr(newI);
    elseif strcmp(t_imgs(nimg),'HSV')
        IMG = rgb2hsv(newI);
    elseif strcmp(t_imgs(nimg),'Lba')
        [nl,nc]=size(newI);
        meio=int16(nl)/2; %dividir a imagem p/evitar overflow
        newI1=newI(1:meio, :, :);
        newI2=newI(meio+1:nl, :, :);
        cform = makecform('srgb2lab');
        IMG1 = applycform(newI1,cform);
        IMG2 = applycform(newI2,cform);
        IMG=vertcat(IMG1,IMG2); %unir a imagem
        clear IMG1 IMG2 newI1 newI2;
    elseif strcmp(t_imgs(nimg),'RGB')
        IMG=newI;
    end

    %salvando as imagens nos vários formatos
    um=ones(nlinhas,1); %um -> classe inicial
    x=1; y=2;
    for ii=1:nclass
        tAm=zeros(nlinhas,1); %tipo amostra -> Zero
        C=[amostras(:,x:y)];
        P = impixel(IMG,C(:,1),C(:,2)); % vetor Banda 1, 2 e 3
        indA=amostrarand(20,50); % randomicamente 20 amostras
        tAm(indA)=1; %vetor utilizados como amostras
        A = [A; nimg*um C(:,1) C(:,2) P um*ii tAm];
        x=x+2; y=y+2;
    end

end %for nimg

%salvando o arquivo final de amostragem
save(arq2,'A','-ASCII');

end % narqs

```

#### **d) Função Discriminate Quadrática**

```

%
% Programa para segmentar uma imagem em K classes com base em
funções
% discriminantes quadraticas
%
% código adaptado ao usado na disciplina Eng.639, Proc.Imagem,
% Prof.Francisco (2010)
%
% Marley Lamounier Machado - DEA (Fev.2012)

clear all

% seleciona arquivos
[filename, pathname, filterindex] = uigetfile('*.*JPG', 'Selecione
imagens', 'MultiSelect', 'on');
[l,narqs]=size(filename);

%seleciona tipo de imagem a ser processada
t_imgs = {'yCbCr','HSV','Lba','RGB'};

```

```

%selecionando o numero de classes
nc=inputdlg('Numero de Classes','');
nclass=str2num(nc{1,1});

%processamento

for k=1:narqs
    disp(['Processando imagem...' num2str(k)]);

    %identificando os arquivos
    arqI = filename{1,k}; %pasta(k,1).name;
    arqI=fullfile(pathname, arqI); %arquivo de imagem
    arqA= regexprep(arqI, '.JPG', '.amt'); % arquivo .amt -> amostra

    %padronizando imagens
    I=imread(arqI);
    for i=1:3
        mini=double(min(min(I(:,:,i))));
        maxi=double(max(max(I(:,:,i))));
        im=((double(I(:,:,i))-mini)/(maxi-mini));
        newI(:,:,i)=uint8(im*255);
    end

    A=[];
    amostras=load(arqA, '-ASCII');
    for ti=1:4 %loop tipo de imagem

        if ti==1 %yCbCr
            %ti
            IMG = rgb2ycbcr(newI);
        elseif ti==2 %HSV
            %ti
            IMG = rgb2hsv(newI);
        elseif ti==3 %Lba
            %ti
            cform = makecform('srgb2lab');
            IMG = applycform(newI,cform);
        else %RGB
            %ti
            IMG=newI;
        end
        idx=find(amostras(:,1)==ti & amostras(:,8)==1);
        A=amostras(idx,:);
        A=A(:,4:7); % Banda1, Banda2, Banda3, Classe

        % verifica se ha e corrige valores NaN nas amostras
        [LNaN,CNaN]=find(isnan(A));
        [L,C]=size(LNaN);
        if L>0
            for i=1:L %num de linhas com NaN
                idl=find(~isnan(A(:,CNaN(i))) & ...
                    A(:,4)==A(LNaN(i),4));
                A(LNaN(i),CNaN(i))=uint8(mean(A(idl,CNaN(i))));
            end
        end
    end

    [nlinhas,ncols]=size(A);

```

```

nc=max(A(:,ncols)); %Determinando o numero de classes
cor=255/(nc+1);

%Criando matriz dque recebera a amostra de cada classe
Ac=cell(1,nc);
for i=1:nlinhas
    nl=size(Ac{1,A(i,ncols)},1);
    Ac{1,A(i,ncols)}(nl+1,:)=A(i,1:ncols-1);
end

%Criando uma matriz de matrizes de covariancia,
determinante, vetor media e inversa da matriz de covariancia de cada
classe
Acov=cell(1,nc);
Adet=zeros(1,nc);
Amed=cell(1,nc);
Icov=cell(1,nc);
for i=1:nc
    Acov{1,i}=cov(Ac{1,i});
    Amed{1,i}=mean(Ac{1,i});
    Adet(1,i)=det(Acov{1,i});
    Icov{1,i}=inv(Acov{1,i});
end

[ml,mc]=size(IMG(:,:,1));
imc=uint8(zeros(ml,mc));% Imagem classificada

%Classificando cada pixel da imagem
[ml,mc]=find(newI(:,:,1)>20);
[nli,i]=size(ml);
[nco,j]=size(mc);
for i=1:nli
    x(1,1)=IMG(ml(i),mc(i),1);
    x(1,2)=IMG(ml(i),mc(i),2);
    x(1,3)=IMG(ml(i),mc(i),3);
    x=double(x);
    for z=1:nc
        d(1,z)=log(1/nc)-0.5*log(Adet(1,z))-0.5* ...
            ((x-Amed{1,z})*Icov{1,z}*(x-Amed{1,z})');
    end
    [y,classe]=max(d); % determinando a classe
    imc(ml(i),mc(i))= uint8(cor*classe);
end

%salvando a imagem
idx=find(imc(:,:,1)==0);
imc(idx)=255; %inverte preto com branco
arqIC=regexp(arqI,'.JPG',...
    strcat('-cdq-',t_imgs(1,ti),'.JPG'));
imwrite(imc,arqIC);

end
clear newI
end

```

## e) Calculo do índice Kappa e ISD

```
%
% Calculo do Coef. Kappa e Indice de Severidade de Doenças
%
% Marley/UFV/DEA - Maio/2012

% Estrutura do arquivo de amostras(.amt):
%[Tipo_Imagem, CoordX, CoordY, Banda1, Banda2, Banda3, Classe,
Tipo_Amostra]
% Tipo_Imagem: yCbCr (1),HSV(2), Lba(3),RGB(4)
% Tipo_amostra: Treinamento(1),Validação(0)

clear all
% seleciona arquivos
[filename, pathname, filterindex] = uigetfile('*-cdq-*.JPG',
'Selecione imagens', 'MultiSelect', 'on');
[l,narqs]=size(filename);
arqOUT=inputdlg('Arquivo de Saida:','');
arqOUT=fullfile(pathname, strcat(arqOUT{1,1},'.xls'));

%processamento
nc=3; %numero de classes

for k=1:narqs
    disp(['Processando imagem...' num2str(k)]);

    %identificando os arquivos

    arqIC = filename{1,k}; %arquivo de imagem classificada
    arqIC=fullfile(pathname, arqIC); %arquivo de imagem
    idx=findstr(arqIC,'-cdq')-1;
    arqA=strcat(arqIC(1:idx),'.amt');% arquivo .amt -> amostra
    timg=arqIC(idx+6:idx+8); %tipo de imagem
    ni=uint8(strmatch(timg, strvcat('yCbCr','HSV','Lba','RGB')));
    np=filename{1,k}(2);
    if (uint8(filename{1,k}(3))>=48 & uint8(filename{1,k}(3)) <=57)
        np=filename{1,k}(2:3);
    end
    parcela=uint8(str2num(np)); %numero da parcela

    %lendo imagens classificadas e atribuindo valor de classe
    IC=imread(arqIC);
    [nli,nci]=size(IC);
    id1=find(IC<95); %classe 1
    id2=find(IC>=95 & IC<160); %classe 2 = ISD
    id3=find(IC>=160 & IC<224); %classe 3
    id4=find(IC>=224); %classe 0 = fundo
    IC(id1)=1; IC(id2)=2; IC(id3)=3; IC(id4)=4; %Redef.classes

    %calculo do Indice de Severidade de Doença -ISD
    verde=size(id1,1); %area verde das folhas
    necrose=size(id2,1); %área de necrose
    clorose=size(id3,1); %área de clorose
    isd(parcela,ni)=necrose*100/(verde+necrose+clorose); % %ISD
    Verdes(parcela,ni)=verde;
    Necroses(parcela,ni)=necrose;
    Cloroses(parcela,ni)=clorose;
```

```

%lendo amostras
amostras=load(arqA, '-ASCII');
idx=find(amostras(:,1)==ni & amostras(:,8)==0); % validação
A=amostras(idx,:);
[nlinhas,co]=size(A);
inter=[]; %pixel imagem interpretada
for i=1:nlinhas
    if (A(i,3) <= nli & A(i,2) <= nci) %exclui amostras erradas
        inter = [inter; IC(A(i,3),A(i,2))];
    end
end
idx=find(inter<4); %exclui amostras erradas
inter=inter(idx);
verd=uint8(A(:,7)); %verdade amostrada (Classe)
verd=verd(idx);
[nlinhas,co]=size(inter);

%estabelecendo a matriz de confusão
matconf=zeros(nc,nc);
for li=1:nlinhas %verdade = amostras
matconf(verd(li,1),inter(li,1))=matconf(verd(li,1),inter(li,1))+1;
end

%Totais observados
Sdiag=sum(diag(matconf));
Scol=sum(matconf);
Slin=sum(matconf');
Slin=Slin';
Sgeral=sum(sum(matconf));
observ=Sdiag/Sgeral;

%matriz de confusão para valores corretos
matconf=zeros(nc,nc);
for l=1:nc
    for c=1:nc
        matconf(l,c)=Scol(l,c)*Slin(l,1);
    end
end

%Totais corretos
Sdiag=sum(diag(matconf));
Scol=sum(matconf);
Slin=sum(matconf');
Slin=Slin';
Sgeral=sum(sum(matconf));
correto=Sdiag/Sgeral;

%Kappa
Kappa(parcela,ni)= (observ-correto)/(1-correto);

end %k

%montando tabela de dados p/salvar
disp('Salvando dados...');
np=size(Kappa,1);
Timg={'Parcela','yCbCr ','HSV ','Lba ','RGB '};

```

```

M=[]; parcela=[]; M.parcela=[]; M.Mimg=[]; idx=[];
for i=1:np %estrutura para guardar os valores do melhor Kappa
    [l,c]=max(Kappa(i,:)); %melhor kappa
    M(i,1).parcela=i;
    for p=1:4 %guardando o nome das melhores imagens pelo kappa
        if (l==Kappa(i,p))
            M(i,1).Mimg=[M(i,1).Mimg Timg{1,p+1}];
            idx=[idx p];
        end
    end
    M(i,1).Mkappa=Kappa(i,c);
    %M(i,1).Misd=isd(i,c); %isd
    M(i,1).Misd=mean(isd(i,idx)); % media dos melhores isd's
    M(i,1).Mverde=Verdes(i,c);
    M(i,1).Mnecrose=Necroses(i,c);
    M(i,1).Mclorose=Cloroses(i,c);
    parcela=[parcela;i];
end
MC = struct2cell(M);
warning off
Kappa=[parcela Kappa];

%salvando dados
xlswrite(arqOUT, Timg, 'Kappas');
xlswrite(arqOUT, Kappa, 'Kappas','A2');
isd=[parcela isd];
xlswrite(arqOUT, Timg, 'ISD');
xlswrite(arqOUT, isd, 'ISD','A2');
xlswrite(arqOUT,
{'PARCELA','IMAGEM','KAPPA','ISD','VERDE','NECROSE','CLOROSE'},
'Melhores');
xlswrite(arqOUT, MC, 'Melhores','A2');
warning on
disp('Ok');

```

## f) Seleção de amostras para usar regressão PLS

```

%%% Seleção de amostras para usar PLSR
%
% Detecta outliers das amostras de validação.
% Salva as amostras em arquivos binários na pasta de trabalho para
usar no
% processamento da PLS
%
% Processa depois de EqMultMB e MA; e antes de classifAmostra

% SAIDA:
% amostraplslr.tipoX;           :           : espectrometria
ou IV
% amostraplslr.matriz
% Parc           : coluna 1           : num. das
parcelas
% classify1           : coluna 2
% outliers_y         : coluna 3, 4,
% classify2           : coluna 5

```

```

% Y : coluna 6, 7, 8 : medidas de
doença
% X : coluna 9-609 : matri X
%
% Marley Lamounier Machado
% Dea Setembro/2012
%

continua={'Sim'};
while strcmp(continua,'Sim')
    clc
    close all
    clear all

    % obtendo parâmetros iniciais

    prompt = {'Experimento: (1:UFV-MA; 2:UFV-MB; 3:ORA-MB; 4:UFV-
MA2; 5:ORA-MA)',...
'Tipo de preprocessamento: ( 1:média; 2:autoescala;
3:nenhum)'};
    dlg_title = 'Detecção de Outliers';
    num_lines = 1;
    def = {'1','1','1'};
    resp = inputdlg(prompt,dlg_title,num_lines,def);
    if isempty(resp)
        return
    end
    switch resp{2}
        case '1'
            preproc='mean';
        case '2'
            preproc='auto';
        case '3'
            preproc='none';
    end
    switch resp{1}
        case '1' %UFV-MA
            tit={'ISD(MA)'};
            coli=3;
            cd('C:\experimentos\Resultados\ufv\ma\multivariado');
        case '2' %UFV-MB
            tit={'ISD(MB)', 'AVALIAÇÃO(MA)', 'AVALIAÇÃO(ANTRACNOSE)'};
            coli=4;
            cd('C:\experimentos\Resultados\ufv\mb\multivariado');
        case '3' %ORA-MB
            tit={'ISD(MB)', 'AVALIAÇÃO(MA)', 'AVALIAÇÃO(ANTRACNOSE)'};
            coli=5;

        case '4' %UFV-MA2
            tit={'ISD(MA)'};
            coli=3;
            cd('C:\experimentos\Resultados\ufv\ma2\multivariado');
        case '5' %ORA-MA
            tit={'ISD(MA)'};
            coli=3;

    end

    cd('C:\experimentos\Resultados\oratorios\ma\multivariado');

```

```

end

%abrindo o arquivo
[filename, pathname, filterindex] = uigetfile('*.txt', 'Escolha
os arquivos', 'MultiSelect', 'off');
arqref=filename(1,:,:)
pasta=pathname(:,:,:)

%obtendo dados
dados=importdata(fullfile(pasta,arqref),' ',1);
[nt,p]=size(dados.data);
X=dados.data(:,coli:coli+600); %formato original
X=X(:,41:501) %retira mais extremos. Banda util: 440(azul) a 900
(fim infravermelho)=461 bandas
Y(:,1:coli-1)=dados.data(:,1:coli-1); %parcelas vão junto para
aleatorizar
classif(1:size(Y,1),1)=0; %sem classificação:
calibração/validação

%divisão dos grupos: Calibração(c) e Validação(v)
Parc=Y(:,1); %parcelas
nY=NaN(size(X,1),3);
nY(:,1:coli-2)=Y(:,2:coli-1);
Y=nY;

%identificando outliers
outliers_y=NaN(size(Y),3);
okx=1;
fim=min(2,coli-2); %evitar que 3a. coluna de Y entre
for i=1:fim
    outliers_y(:,i)=0; %inicializa com nenhum outliers
    disp(strcat('##### Y[' num2str(i),'] #####'));
    % numero de variavel latentes
    figure('name',arqref)
    escvlops(X,Y(:,i),preproc,1);
    nvl=inputdlg('Numero de variáveis latentes');
    close %fecha figura atual
    nvl=str2num(nvl{1});
    %Outlier por distâncias robustas (X)
    if okx
        [nX, nP, outliers_x]=
dist_robusta(X,Parc,tit{i},arqref);
        okx=0;
    end
    %Outlier (Y)
    [nY, nP, outly]=zscoreRob(Y(:,i),Parc,tit{i},arqref,1);
    %Outlier resíduos PSLR
    [b Yest]=calc_plsr(X,Y(:,i),preproc,nvl);
    res=Y(:,i)-Yest;
    [nY, nP, outlxy]=zscoreRob(res,Parc,tit{i},arqref,2);
    sprintf('%s\n\n',' ');
    %input('<Enter> para continuar. ');
    %todas parcelas com outliers
    outliers=outliers_x+outlxy+outly;
    idx=find(outliers);
    if ~isempty(idx)
        ParcOutl=Parc(idx);
        str=num2str(Parc(idx)); %parcelas c/outliers

```

```

        [idx,ok] = listdlg('PromptString','Selecione as
parcelas com Outliers:',...
'SelectionMode','multiple','ListSize',[200 100],...
'ListString',str);
    if ok
        ParcOutl=ParcOutl(idx);
        n=length(idx);
        idx=[];
        for j=1:n %Indice final com outliers
            k=1;
            while ParcOutl(j)~=Parc(k)
                k=k+1;
            end
            idx=[idx k];
        end
        outliers_y(idx,i)=1;
    end
end %if
if coli-2>1 %se mais que 1 Y
    disp(' ');
    input('<Enter> para continuar.');
```

end

```

    %salvando amostras limpas
    amostraplslr.tipoX=1; %espectrometria;
    amostraplslr.matriz=[Parc classif outliers_y Y X];
    save(fullfile(pasta,strrep(arqref,'.txt',strcat('-
',resp{2},'.mat'))),'amostraplslr');
    %resp{2}: tipo de preprocessamento usado aqui no nome do arquivo
    disp('');
    disp(strcat('>> Arquivo
Salvo:',fullfile(pasta,'amostraPLSR.mat')));
    cd('C:\experimentos\mfiles-Tese\PSLR\1Y');
```

```

    continua = questdlg('Continua?','Outliers','Sim','Não','Sim');
    disp(' ');
    %input('<Enter> para continuar.');
```

end

```

cd(pathname);
```

### g) Identificação de outliers (z score robusto)

```

function [nY, nP, idy]=detoutlier(Y,Parc,tit,arqref,tipo)
%detecção de outlier
%Entrada
% Y medidos
% Parc: número das parcelas
% tipo: 1-y; 2=resíduos
%Saida
% nY, Np: valores limpos de Y e parcelas
%Artigo Fonte
%
```

```

%Marley Lamounier Machado
%Dea/UFV Set/2012
%

%inicialização
c=3;
ol=[];
idy=zeros(size(Y,1),1); %condição inicial = sem outliers, idy =1
nY=Y; nP=Parc;

%calculo
med=median(nY);
Qn=qn(nY); % sistema TOMCAT
zc=abs(nY-med)/Qn;
id0=find(zc>3); %identifica outliers
idy(id0,1)=1; % 1 identificador de outlier
nY(id0,:)=NaN;
nP(id0,:)=NaN;
id0=find(~isnan(nY));
nY=nY(id0,:);
nP=nP(id0,:);

%gráfico
if tipo==1
    tity='Z-Scores (Robusto)'; %titulo Y
    titfig=strcat(arqref,'-1'); %titulo windowsi
    pos=[440 246 400 300];
else
    tity='Z-Scores (Robusto) de resíduo PLSR';
    titfig=strcat(arqref,'-2');
    pos=[860 246 400 300];
end
figure('name',titfig,'Position',pos)
yl= max(max(3.5,zc+0.5));
vl=find(zc>=0);
plot(vl,zc,'o');
text(vl+0.005,zc,num2str(-Parc),'HorizontalAlignment','left')
ylim([0 yl])
ylabel(tity)
xlabel('Sequencia')
title(tit)
holin(3,'-r')

```

## h) Separa grupos de Calibração e validação

```

%%% Classifica Amostras (Validação e Calibração)
%
% Usado após o programa amostrasPLSR e antes do programa
processaPLSR
%
% Marley Lamounier Machado
% Dea/UFV Novembro/2012
%

perc_am=0.7; %percentual de amostragem de validação e calibração;
%%abrindo o arquivo

```

```

str={'UFV-MA(Foliar)', 'UFV-MB(Foliar)', 'ORA-MB(Foliar)', 'ORA-
MA(Foliar)', 'UFV-MA2(Foliar)', ...
    'UFV-MA(Dossel)', 'UFV-MB(Dossel)', 'ORA-MB(Dossel)', 'ORA-
MA(Dossel)', 'UFV-MA2(Dossel)'};
[mLin, mCol] = listdlg('PromptString', 'Selezione um experimento:', ...
    'SelectionMode', 'single', ...
    'ListString', str);

if mCol==0
    return
end
if mLin==1

dir_out='C:\experimentos\Resultados\ufv\ma\multivariado\espectrometr
ia foliar';
    ny=1;
elseif mLin==2

dir_out='C:\experimentos\Resultados\ufv\mb\multivariado\espectrometr
ia foliar';
    ny=2;
elseif mLin==3

dir_out='C:\experimentos\Resultados\oratorios\mb\multivariado\espectr
ometria foliar';
    ny=2;
elseif mLin==4

dir_out='C:\experimentos\Resultados\oratorios\ma\multivariado\espectr
ometria foliar';
    ny=1;
elseif mLin==5

dir_out='C:\experimentos\Resultados\ufv\ma2\multivariado\espectrometr
ia foliar';
    ny=1;
elseif mLin==6

dir_out='C:\experimentos\Resultados\ufv\ma\multivariado\espectrometr
ia dossel';
    ny=1;
elseif mLin==7

dir_out='C:\experimentos\Resultados\ufv\mb\multivariado\espectrometr
ia dossel';
    ny=2;
elseif mLin==8

dir_out='C:\experimentos\Resultados\oratorios\mb\multivariado\espectr
ometria dossel';
    ny=2;
elseif mLin==9

dir_out='C:\experimentos\Resultados\oratorios\ma\multivariado\espectr
ometria dossel';
    ny=1;
else

dir_out='C:\experimentos\Resultados\ufv\ma2\multivariado\espectrometr
ia dossel';
    ny=1;

```

```

end
cd(dir_out);

%escolher os Y's
if ny==2
    stry={'Ambos','1','2'};
    [mliny,mcoly] = listdlg('PromptString','Selecione Y a
processar:',...
                           'SelectionMode','single',...
                           'ListString',stry);

    if mcoly==0
        return
    end
    if mliny==1
        yini=1;
        yfim=2;
    elseif mliny==2
        yini=1;
        yfim=1;
    else
        yini=2;
        yfim=2;
    end
end

%lendo dados
[filename, pathname, filterindex] = uigetfile('*.mat', 'Escolha o
arquivo', 'MultiSelect', 'on');
if filterindex==0
    return
else
    if iscell(filename)
        narq=length(filename);
    else
        narq=1;
    end
end

%pasta=pathname(:, :, :);
for j=1:narq

    if narq==1
        arqref=filename;
    else
        arqref=filename{1,j};
    end
    load(arqref, '-mat');
    dados=amostraplsr.matriz;
    [dados,Y] = aleatoriza(dados,dados(:,1)); %aleatoriza

    for i=yini:yfim %processando pela quantidade de Y (ny)

        disp(strcat('##### Y(',num2str(i),') #####'));

        % separando amostras anômalas
        idx=find(dados(:,i+2)==0); %encontra amostras limpas
        nt=length(idx); %numero total de amostras limpas
        nac=round(nt*perc_am); % numero de amostras para calibração
        if i==1

```

```

        colc=2; %coluna da classificação
    else
        colc=5;
    end
    n=1; nc=1;
    dados(1:nt,colc)=0; %inicializa todos valores de para 0
    dados(idx,colc)=2; % inicializa amostras limpas como
validação
    while (nc<=nac)
        if dados(n,i+2)==0; %se não for outlier, classifica como
1 (calibração)
            dados(n,colc)=1;
            nc=nc+1;
        end
        n=n+1;
    end

    end %for

    % salvar
    amostraplsr.matriz=dados;
    save(arqref,'amostraplsr');
    disp('');
    disp(strcat('>> Arquivo Salvo:',arqref));

end %while
cd('C:\experimentos\mfiles-Tese\PSLR\1Y');

```

## i) Processa regressão PLS

```

%%% Processa PLSR
%
% Marley Lamounier Machado
% Dea/UFV Setembro/2012
%
% este aplicativo vem apos o classifAmostra e antes do aplicativo
resPLSRexp
%
% le arquivo '.mat' na pasta do emperimento e grava resultados em
subpasta
% com nome da data processada. O programa resPLSR apresentará os
resultados
% finais. Nesta subpasta, gravará, ainda, todas as imagens geradas.
% No caso de 2 y's, gravara na subpasta dois arquivos de finais y1 e
y2.

clear all
close all

%%abrindo o arquivo
str={'UFV-MA (Foliar) ', 'UFV-MB (Foliar) ', 'ORA-MB (Foliar) ', 'ORA-
MA (Foliar) ', 'UFV-MA2 (Foliar) ', ...
    'UFV-MA (Dossel) ', 'UFV-MB (Dossel) ', 'ORA-MB (Dossel) ', 'ORA-
MA (Dossel) ', 'UFV-MA2 (Dossel) '};
[mLin,mcol] = listdlg('PromptString','Selecione um experimento:',...
    'SelectionMode','single',...
    'ListString',str);

```

```

if mcol==0
    return
end
if mlin==1

dir_out='C:\experimentos\Resultados\ufv\ma\multivariado\espectrometr
ia foliar';
    ny=1;
elseif mlin==2

dir_out='C:\experimentos\Resultados\ufv\mb\multivariado\espectrometr
ia foliar';
    ny=2;
elseif mlin==3

dir_out='C:\experimentos\Resultados\oratorios\mb\multivariado\espectr
ometria foliar';
    ny=2;
elseif mlin==4

dir_out='C:\experimentos\Resultados\oratorios\ma\multivariado\espectr
ometria foliar';
    ny=1;
elseif mlin==5

dir_out='C:\experimentos\Resultados\ufv\ma2\multivariado\espectrometr
ia foliar';
    ny=1;
elseif mlin==6

dir_out='C:\experimentos\Resultados\ufv\ma\multivariado\espectrometr
ia dossel';
    ny=1;
elseif mlin==7

dir_out='C:\experimentos\Resultados\ufv\mb\multivariado\espectrometr
ia dossel';
    ny=2;
elseif mlin==8

dir_out='C:\experimentos\Resultados\oratorios\mb\multivariado\espectr
ometria dossel';
    ny=2;
elseif mlin==9

dir_out='C:\experimentos\Resultados\oratorios\ma\multivariado\espectr
ometria dossel';
    ny=1;
else

dir_out='C:\experimentos\Resultados\ufv\ma2\multivariado\espectrometr
ia dossel';
    ny=1;
end
cd(dir_out);

yini=1;
yfim=1;
if ny==2
    stry={'Ambos','1','2'};

```

```

    [mliny,mcoly] = listdlg('PromptString','Selecione Y a
processar:',...
                           'SelectionMode','single',...
                           'ListString',stry);
    if mcoly==0
        return
    end
    if mliny==1
        yini=1;
        yfim=2;
    elseif mliny==2
        yini=1;
        yfim=1;
    else
        yini=2;
        yfim=2;
    end
end

% tipo de preprocessamento
str={'auto','mean','None'};
[npreproc,mcol] = listdlg('PromptString','Selecione um
preprocessamento:',...
                          'SelectionMode','single',...
                          'ListString',str);
if mcol==0
    return
end
preproc=str{npreproc};

resposta='Sim';
while strcmp(resposta,'Sim')

    %lendo dados
    [filename, pathname, filterindex] = uigetfile('*.mat', 'Escolha
o arquivo', 'MultiSelect', 'off');
    arqref=filename(1,:,:)';
    load(arqref,'-mat');
    dados=amostraplsr.matriz;

    %opção para gravar imagem
    gravaring=lower(input('Gravar imagens <s/n> :','s'));
    filenamefig=[];
    if gravaring(1) == 's'
        filenamefig=strrep(arqref,'.mat','');
    end

    % Gráfico de reflec. 3d
    [md idm]=sort(mean(dados(:,9:469),2));
    figure
    X0=440:900;
    m=size(dados,1);
    Y0=1:m;
    [Xm,Ym] = meshgrid(X0,Y0);
    Z0 = dados(idm,9:469);
    mesh(X0,Y0,Z0)
    colormap (cool)
    colorbar('location','northoutside')

```

```

ylabel('Numero de observações','Rotation',-24)
xlabel('Comprimento de onda (nm)','Rotation',15)
zlabel('Reflectancia','Rotation',90)
axis([440 900 1 m 0 1])
input('>>> Enter para continuar');
print -djpeg -f1 f1;

for i=yini:yfim %processando pela quantidade de Y (ny)

    disp(strcat('##### Y(',num2str(i),') #####'));

    % separando amostras anômalas
    if i==1
        colc=2;
    else
        colc=5;
    end
    id1=find(dados(:,colc)==1); %calibração
    id2=find(dados(:,colc)==2); %validação
    nvc = length(id1); %numero variáveis calibração
    nvv = length(id2); %numero variáveis valibração

    %separando amostras de calibração e validação
    Parcc=dados(id1,1);
    Yc=dados(id1,i+5);
    Xc=dados(id1,9:469); %609 (antigo)
    Parcv=dados(id2,1);
    Yv=dados(id2,i+5);
    Xv=dados(id2,9:469);

    %%Processamento

    nret=1; %Leave-nret-out
    ivs=false; %não indice de vegetação

    [result,varsels] = opswizard(Xc,Yc,1,preproc); %obtendo
modelo
    nvar=varsels.resultSEL(1,2); %numero de variáveis
    nlv=varsels.resultSEL(1,3); %numero de variáveis latentes
    rmsec=varsels.resultSEL(1,4); %erro quadrático médio
    Yestc=varsels.tabMPRE(:,3); %valores estimados de Y
    [beta Y0]=calc_plsr(Xc(:,varsels.varsel),Yc,preproc,nlv);
    %obtem novo beta com parametros do modelo escolhido

    %aplicando modelo nas amostras de validação
    [X1,media,desvio] =
preprocessa(Xv(:,varsels.varsel),npreproc); %faz transf. e obtem
média e desvio das bandas selecionadas
    [Y1,mediay,desvioy] = preprocessa(Yv,npreproc); %faz transf.
e obtem média e desvio da Mariz Y
    Yestv = X1*beta; %aplica modelo
    Yestv = reescala(Yestv,mediay,desvioy,npreproc); %converte
de padronizado para escalar
    rmsev = sqrt(sum((Yv-Yestv).^2)/nvv);

    %teste de significancia (p menor que 0.05: verdadeiro e
estimado são iguais)
    [pv,x2v,dfv]=calcx2(Yv,Yestv); %chi-quadrado validação

```

```

[pc,x2c,dfc]=calcx2(Yc,Yestc); %chi-quadrado calibração
[rv,pcv]=corrcoef(Yv,Yestv);
[rc,pcc]=corrcoef(Yc,Yestc);

%gráfico correlação
figure
subplot(1,2,1)
plot(Yc,Yestc,'o'); % Valores preditos pela validação
cruzada na VL
dlin
title({' Calibração'; strcat('r=',num2str(rc(1,2)),'
(p=',num2str(pcc(1,2)),')')});
xlabel ('Valores Medidos')
ylabel ('Valores Preditos (CV)')
subplot(1,2,2)
plot(Yv,Yestv,'o'); % Valores preditos pela validação
cruzada na VL
dlin
title({' Validação'; strcat('r=',num2str(rv(1,2)),'
(p=',num2str(pcv(1,2)),')')});
xlabel ('Valores Medidos')
ylabel ('Valores Preditos ')

%resumo
resumo.corrc=rc(1,2); %correl calibração
resumo.corrv=rv(1,2); %correl validação
resumo.pc_c=pcc(1,2); %pvalue corr.calib
resumo.pc_v=pcv(1,2); %pvalue corr.valid
resumo.px2_v=pc; %pvalue x².valid
resumo.px2_c=pv; %pvalue x².calib
resumo.x2v=x2v; %chi-square validação
resumo.x2c=x2c; %chi-square calibração
resumo.dfv=dfv; %graus de liberdade validação
resumo.dfc=dfc; %graus de liberdade calibração
resumo.rmsec=rmsec; %erro médio quad-calibração
resumo.rmsev=rmsev; %erro médio quad-
validaçãoresumo.Yestv=Yestv; %valor estimado de y-validação
resumo.nvc=nvc; % num. de parcelas uteis p/calibração- sem
outliers
resumo.nvv=nvv; %numero parcelas uteis p/validação - sem
outliers
resumo.nvl=nlv; %numero de variáveis latentes
resumo.nvar=nvar; %numero bandas selecionadas
resumo.betas=beta; %betas correspondentes às bandas
selecionadas

%resumindo bandas
[bands, idb]=sort(varsels.varsel+439); %bandas selecionadas
j=2;
interv=[];
ini=bands(1);
fim=bands(1);
while j<=nvar
    if (bands(j)-bands(j-1))>1
        interv=[interv strcat('[' ,num2str(ini),'-
',num2str(fim),']')];
        ini=bands(j);
        fim=bands(j);
    else

```

```

        fim=bands(j);
    end
    j=j+1;
end
interv=[interv strcat([' ',num2str(ini),'-
',num2str(fim),''])];
resumo.bandsets=interv;

%salvando informações
fileres=strrep(arqref, '.mat', '');
if i==1
    fileres=strcat('r_',fileres,'-y1.mat');
else
    fileres=strcat('r_',fileres,'-y2.mat');
end
save(fileres, 'resumo', 'result', 'varsels'); %resultado
final
if ~isempty(filenameefig) % <== se nome não esta vazio, salva
figura atual
    mkdir(filenameefig);
    cd(filenameefig);
    system('move ..\f1.jpg refler.jpg'); %coloca título
    system(strcat('move ..\' ,fileres, ' .')); %coloca título
    if i==1 %Y=1
        print -djpeg -f2 f2y1;
        print -djpeg -f3 f3y1;
        print -djpeg -f4 f4y1;
        print -djpeg -f5 f5y1;
        print -djpeg -f6 f6y1;
        print -djpeg -f7 f7y1;
        %print -djpeg -f8 f8y1;
    else %y=2
        print -djpeg -f2 f2y2;
        print -djpeg -f3 f3y2;
        print -djpeg -f4 f4y2;
        print -djpeg -f5 f5y2;
        print -djpeg -f6 f6y2;
        print -djpeg -f7 f7y2;
        %print -djpeg -f8 f8y2;
    end
    cd('..')
end

end %for

resposta=questdlg('Deseja processar outra
data?', 'Equações', 'Sim', 'Não', 'Sim');
if strcmp(resposta, 'Sim')
    close all
end

end %for

```

## j) Índices de vegetação Hiperespectrais

```
%índices de vegetação hiperspectrais
```

```

%
%
% Marley/DEA
%

%Seleção de pastas de trabalho e arquivos

close all
clear all
clc

%%abrindo o arquivo
str={'UFV-MA (Foliar) ', 'UFV-MB (Foliar) ', 'ORA-MB (Foliar) ', 'ORA-
MA (Foliar) ', 'UFV-MA2 (Foliar) ', ...
    'UFV-MA (Dossel) ', 'UFV-MB (Dossel) ', 'ORA-MB (Dossel) ', 'ORA-
MA (Dossel) ', 'UFV-MA2 (Dossel) '};
[mLin,mcol] = listdlg('PromptString','Selecione um experimento:',...
    'SelectionMode','single',...
    'ListString',str);
if mcol==0
    return
end
inisdata=8; %início da string data no nome do arquivo
if mlin==1

dir_out='C:\experimentos\Resultados\ufv\ma\multivariado\espectrometr
ia foliar';
    ny=1;
elseif mlin==2

dir_out='C:\experimentos\Resultados\ufv\mb\multivariado\espectrometr
ia foliar';
    ny=2;
elseif mlin==3

dir_out='C:\experimentos\Resultados\oratorios\mb\multivariado\espect
rometria foliar';
    ny=2;
elseif mlin==4

dir_out='C:\experimentos\Resultados\oratorios\ma\multivariado\espect
rometria foliar';
    ny=1;
elseif mlin==5

dir_out='C:\experimentos\Resultados\ufv\ma2\multivariado\espectrometr
ia foliar';
    ny=1;
    inisdata=9;
elseif mlin==6

dir_out='C:\experimentos\Resultados\ufv\ma\multivariado\espectrometr
ia dossel';
    ny=1;
elseif mlin==7

dir_out='C:\experimentos\Resultados\ufv\mb\multivariado\espectrometr
ia dossel';
    ny=2;

```

```

elseif mlin==8

dir_out='C:\experimentos\Resultados\oratorios\mb\multivariado\espect
rometria dossel';
    ny=2;
elseif mlin==9

dir_out='C:\experimentos\Resultados\oratorios\ma\multivariado\espect
rometria dossel';
    ny=1;
else

dir_out='C:\experimentos\Resultados\ufv\ma2\multivariado\espectromet
ria dossel';
    ny=1;
    inisdata=9;
end
cd(dir_out);

[filename, pathname, filterindex] = uigetfile('*.*mat', ...
        'Selecione Arquivo', 'MultiSelect', 'on');
[i,narqs]=size(filename);

%obtendo valores de datas(ordenadas) no nome do arquivo
narq=size(filename,2);
nomes=char(filename);
datas=nomes(:,inisdata:inisdata+9);
numdata=datenum(datas, 'dd-mm-yyyy');
[numdata,idd]=sort(numdata);
filename=filename(idd);
datas=datas(idd,:);

%processamento
correl=[];
pval=[];
[j,i] = size(filename);
nota=zeros(2,87);
for j=1:narq %i corresponde ao números de arquivos

    %lendo dados
    arqref=fullfile(pathname, filename{j});
    load(arqref,'-mat');
    plan=amostraplsmatriz(:,9:469);
    for y=1:ny
        [nparc,l]=size(plan); % numero de parcelas
        Sny=num2str(y);
        arqout=strrep(arqref, '.mat', strcat('.ivhs.y',Sny, '.mat'));
        ivs=[];

        for z=1:nparc %processando pelo número de doenças

            %seleção de bandas
            r440 = plan(z,440-439);
            r442 = plan(z,442-439);
            r445 = plan(z,445-439);
            r470 = plan(z,470-439);
            r483 = plan(z,483-439);
            r491 = plan(z,491-439);
            r496 = plan(z,496-439);

```

```

r498 = plan(z,498-439);
r500 = plan(z,500-439);
r503 = plan(z,503-439);
r510 = plan(z,510-439);
r527 = plan(z,527-439);
r528 = plan(z,528-439);
r530 = plan(z,530-439);
r531 = plan(z,531-439);
r539 = plan(z,539-439);
r550 = plan(z,550-439);
r554 = plan(z,554-439);
r560 = plan(z,560-439);
r570 = plan(z,570-439);
r573 = plan(z,573-439);
r600 = plan(z,600-439);
r612 = plan(z,612-439);
r635 = plan(z,635-439);
r640_r660 = mean2(plan(z,640-439:660-439));
r650 = plan(z,650-439);
r660 = plan(z,660-439);
r670 = plan(z,670-439);
r672 = plan(z,672-439);
r675 = plan(z,675-439);
r677 = plan(z,677-439);
r680 = plan(z,680-439);
r695 = plan(z,695-439);
r695_r740 = mean2(plan(z,695-439:740-439));
r700 = plan(z,700-439);
r705 = plan(z,705-439);
r708 = plan(z,708-439);
r710 = plan(z,710-439);
r715 = plan(z,715-439);
r717 = plan(z,717-439);
r720 = plan(z,729-439);
r726 = plan(z,726-439);
r730 = plan(z,730-439);
r734 = plan(z,734-439);
r740 = plan(z,740-439);
r747 = plan(z,747-439);
r750 = plan(z,750-439);
r750_r800 = mean2(plan(z,750-439:800-439));
r760 = plan(z,760-439);
r762 = plan(z,762-439);
r765 = plan(z,765-439);
r780 = plan(z,780-439);
r787 = plan(z,787-439);
r790 = plan(z,790-439);
r790_r810 = mean2(plan(z,790-439:810-439));
r790_r720 = mean2(plan(z,790-439:720-439));
r800 = plan(z,800-439);
r801 = plan(z,801-439);
r810 = plan(z,810-439);
r850 = plan(z,850-439);
r860 = plan(z,860-439);
r900 = plan(z,900-439);

%calculo de indices de vegetação
ari=(1/r550)-(1/r700);

```

%1

```

cri1=1/r510-1/r550;
%2
cri2=1/r510-1/r700;
%3
dd=(r750-r720)-(r700-r670);
%4
dvi=r800-r680;
%5
dvi1=r800-r550;
%6
g=r554/r677;
%7
gm=(r750/r550)-1;
%8
gndvi=(r801-r550)/(r800+r550);
%9
ire=(r730-r700)/30;
%10
mcari=((r700-r670)-0.2*(r700-r550))*(r700/r670);
%11
mcari2=(1.5*(2.5*(r800-r670)-1.3*(r800-r550)))/...
sqrt((2*r800+1)^2-(6*r800-5*sqrt(r670))-0.5);
%12
mcari705_750=((r750-r705)-0.2*(r750-
r550))*(r750/r705); %13
mnd705=(r750-r705)/(r750+r705-2*r445);
%14
msavi=0.5*(2*r800+1-sqrt((2*r800+1)^2-8*(r800-
r670))); %15
msr=(r800/r670-1)/sqrt(r800/r670+1);
%16
msr705_750=(r750/r705-1)/sqrt(r750/r705+1);
%17
msr705=(r750-r445)/(r705-r445);
%18
mtci=(r750-r710)/(r710-r680);
%19
mtvi=1.2*(1.2*(r800-r550)-2.5*(r670-r550));
%20
nd705=(r750-r705)/(r750+r705);
%21
ndci=(r762-r527)/(r762+r527);
%22
ndi1=(r780-r710)/(r780-r680);
%23
ndi2=(r850-r710)/(r850-r680);
%24
ndi3=((r750_r800)/(r695_r740))-1;
%25
ndre=(r790-r720)/(r790+r720);
%26
ndvi=(r800-r670)/(r800+r670);
%27
ndvi1=(r734-r747)/(r715+r726);
%28
ndvi2=(r800-r700)/(r800+r700);
%29
ndvi3=(r780-r550)/(r780+r550);
%30

```

```

%31      ndvi4=(r800-r600)/(r800+r600);
%32      ndvi5=(r900-r680)/(r900+r680);
%33      ndvi6=(r760-r708)/(r760+r708);
%34      ndvi7=(r573-r440)/(r573+r440);
%35      ndvi8=(r503-r483)/(r503+r483);
%36      osavi=(1+0.16)*(r800-r670)/(r800+r670+0.16);
%37      osavi705_750=(1+0.16)*(r750-r705)/(r750+r705+0.16);
%38      pri=(r531-r570)/(r530+r570);
%39      pric=(r570-r539)/(r528+r539);
%40      psndb=(r800-r635)/(r800+r635);
%41      psndc=(r800-r470)/(r800+r470);
%42      psri=(r680-r500)/r750;
%43      pssra=r800/r680;
%44      pssrb=r800/r635;
%45      pssrc=r800/r470;
%46      rdvi=(r800-r670)/sqrt(r800+r670);
%47      reip=700+40*((r670+r780)/2-r700)/(r740-r700);
%48      rgr=(r612+r660)/(r510+r560);
%49      rm=(r750/r720)-1;
%50      %rvi=(r790_r810)/(r640_r660);
%51      sipi=(r800-r445)/(r800-r680);
%52      sr1=r801/r670;
%53      sr2=r800/r550;
%54      sr3=r700/r670;
%55      sr4=r740/r720;
%56      sr5=r675/(r700*r650);
%57      sr6=r675/r700;
%58      sr7=r672/(r550*r708);
%59      sr8=r860/(r550*r708);
%60      sr9=r750/r700;

```

```

%61          sr10=r750/r550;
%62          sr11=r900/r680;
%63          sr12=r550/r850;
%64          sr13=r710/r850;
%65          sr16=r750/r705;
%66          sr17=r810/r560;
%67          sr18=r787/r765;
%68          sr19=1/r700;
%69          sr20=r705/(r717+r491);
%70          tcari=3*((r700-r670)-0.2*(r700-r550)*(r700/r670));
%71          tcari705_750=3*((r750-r705)-0.2*(r750-
r550)*(r750/r705));
%72          tci=1.2*(r700-r550)-1.5*(r670-r550)*sqrt(r700/r670);
%73          tvi=0.5*(120*(r750-r550)-200*(r670-r550));
%74          viopt1=100*(log(r760)-log(r730));
%75          viopt2=r760/r730;
%76          ztm=r750/r710;
%77          ari2=r800*ari;
%78          dd_m=dd/msavi;
%79          m_m=mtvi/msavi;
%80          m_o=mcari/osavi;
%81          m_o705_750= mcari705_750/osavi705_750;
%82          rm_msavi=rm/msavi;
%83          tci_o=tci/osavi;
%84          t_o705_750=tcari705_750/osavi705_750;
%85          t_o=tcari/osavi;

ivs=[ivs; ari cri1 cri2 dd dvi dvi1 g gm gndvi ire
mcari mcari2 ...          mcari705_750 mnd705 msavi msr msr705_750 msr705
mtci mtvi nd705 ...          ndci ndi1 ndi2 ndi3 ndre ndvi ndvi1 ndvi2 ndvi3
ndvi4 ndvi5 ...          ndvi6 ndvi7 ndvi8 osavi osavi705_750 pri pric
psndb psndc ...

```

```

psri pssra pssrb pssrc rdvi reip rgr rm sipi srl
sr2 sr3 ...
sr4 sr5 sr6 sr7 sr8 sr9 sr10 sr11 srl2 srl3 srl6
...
sr17 sr18 sr19 sr20 tcari tcari705_750 tci tvi
viopt1 viopt2 ...
ztm ari2 dd_m m_m m_o m_o705_750 rm_msavi tci_o
t_o705_750 t_o];
end

%montando a estrutura
nivs=size(ivs,2);
parc=amostraplsr.matriz(:,1); %parcela
outl=amostraplsr.matriz(:,y+2);
isd=amostraplsr.matriz(:,y+5);
resumoiv.ivs=[parc outl isd ivs];
% parc: col.1
% outl: col 2
% isd: col 3
% ivs: col 4-88
idx=find(resumoiv.ivs(:,2)==0);
resumoiv.ivs=resumoiv.ivs(idx,:); %amostras sem outliers

nomes={'ari','cri1','cri2','dd','dvi','dvi1','g','gm','gndvi',...
'ire','mcari','mcari2','mcari705_750','mnd705','msavi',...
'msr','msr705_750','msr705','mtci','mtvi','nd705','ndci','ndi1',...
'ndi2','ndi3','ndre','ndvi','ndvil','ndvi2','ndvi3','ndvi4',...
'ndvi5','ndvi6','ndvi7','ndvi8','osavi','osavi705_750',...
'pri','pric','psndb','psndc','psri','pssra','pssrb','pssrc',...
'rdvi','reip','rgr','rm','sipi','sr1','sr2','sr3',...
'sr4','sr5','sr6','sr7','sr8','sr9','sr10','sr11','sr12',...
'sr13','sr16','sr17','sr18','sr19','sr20',...
'tcari','tcari705_750','tci','tvi','viopt1','viopt2','ztm',...
'ari2','dd/msavi','mtvi/msavi','mcari/osavi',...
'mcari705_750/osavi705_750','rm/msavi','tci/osavi',...
'tcari705_750/osavi705_750','tcari/osavi'};

%correlações
riv=[];
piv=[];
for z=1:nivs
[r,p] =
corrcoef(resumoiv.ivs(:,3),resumoiv.ivs(:,z+3)); % Compute sample
correlation and p-values.
resumoiv.riv(z) = r(1,2);
resumoiv.piv(z) = p(1,2); % Find significant
correlations.
if p(1,2)<=0.05
nota(y,z)=nota(y,z)+(1-p(1,2)); %contabiliza nota
geral
end

```

```

        correl(z,j,y)=r(1,2); %<-----
        pval(z,j,y)=p(1,2); %<-----
    end

    %melhores ivs
    txt = cell(0);
    txt{end+1} = (' ');
    txt{end+1} = ('          CORRELAÇÕES SIGNIFICATIVAS
ORDENADAS');
    txt{end+1} = ('  ## Índice de Vegetação(IV)   Corr.(r)
p-value');
    txt{end+1} = ('  -- -----
-----');
    idx=find(resumoiv.piv<=0.05);
    if length(idx)==0
        txt{end+1} = ('  NC');
    else
        %seleção dos melhores
        melhores_p=resumoiv.piv(idx); %p-valor
        melhores_r=resumoiv.riv(idx); %correção
        melhores_nomes=nomes(idx);
        %ordenação pela significancia
        [melhores_p,idx]=sort(melhores_p); %este é o
ranging dos melhores ivs
        melhores_r=melhores_r(idx);
        melhores_nomes=melhores_nomes(idx);
        n=length(melhores_p);
        format = ('  %2.0f %25s %8.5f %7.5f');
        for z=1:n %apresenta resultados
            txt{end+1} = sprintf(format,z,melhores_nomes{z},
melhores_r(z),melhores_p(z));
        end
    end
    disp(sprintf('%s - %s -
Y(%1.0f)',str{1,mLin},filename{j},y));
    disp(sprintf('%s\n',txt{:}));

    %salvando arquivos
    save(arqout,'resumoiv');
    disp('');
    %disp(strcat('>> Arquivo Salvo:',arqref));

    % input('<enter> para continuar. ');
end %ny
end

% apresentando resultado finais
for y=1:ny

    %Resultado Final - Parte 1

    txt1 = cell(0);
    %titulo
    txt1{end+1} = (' ');
    disp(sprintf('%s - Y(%1.0f)',str{1,mLin},y));
    txt1{end+1} = ('  TABELA DE CORRELAÇÕES DOS IVs');
    linha=sprintf('  %25s','Índice de Vegetação(IV) ');
    for j=1:narq
        linha=[linha sprintf('%10s',datas(j,1:5))];
    end
end

```

```

end
txt1(end+1)={linha};
%sublinhar titulo
linha=sprintf(' %25s','-----');
for j=1:narq
    linha=[linha sprintf(' %9s','-----')];
end
txt1(end+1)={linha};
for i=1:nivs
    linha=sprintf(' %25s',nomes{i});
    for j=1:narq
        if pval(i,j)<=0.05
            carac='*';
        else
            carac=' ';
        end
        linha=[linha sprintf('%9.5f%1s',correl(i,j,y),carac)];
    end
    txt1(end+1)={linha};
end
disp(sprintf('%s\n',txt1{:}));
disp('');

%Resultado Final - Parte 2

txt = cell(0);
txt{end+1} = (' ');
txt{end+1} = (' NOTAS GERAIS DOS INDICES NO EXPERIMENTO');
txt{end+1} = (' ## Indice de Vegetação(IV) Nota');
txt{end+1} = (' -- -----');
format = (' %2.0f %25s %7.5f');
%disp(sprintf('%s - Y(%1.0f)',str{1,mLin},y));
id=find(nota(y,:)>0);
melhores_nomes=nomes(id);
[notay,idx]=sort(nota(y,id),'descend');
melhores_nomes=melhores_nomes(idx);
nid=length(idx);
for z=1:nid
    txt{end+1} = sprintf(format,z,melhores_nomes{z},notay(z));
end
disp(sprintf('%s\n',txt{:}));
disp('');
end

```

## l) indices de vegetação Multiespectrais

```

function ivs=calcIVmult(mB,mG,mR,mRE,mNIR)
% Calculo de indices de vegetação multiespectral
%
% este aplicativo deve ser rodado antes de amostramPSLR
(multiespectral)
%
% Marley Lamounier Machado
% Jan/2013

%calcula indices

```

COL

```

ARVI=(mNIR-(2*mR-mB))/(mNIR+(2*mR-mB)); %1
DVI = mNIR - mR; %2
EVI=2.5*(mNIR-mR)/(mNIR+6*mR-7.5*mB+1); %3
GDVI = mNIR - mG; %4
GMSAVI2 = 0.5 * (2 * (mNIR + 1) - ... %5
    sqrt((2 * mNIR + 1)^2 - 8 * (mNIR - mG)));
GNDVI = (mNIR - mG) / (mNIR + mG); %6
GRVI = mNIR / mG; %7
GOSAVI = (mNIR - mG) / (mNIR + mG + 0.16); %8
GRDVI = sqrt(GNDVI * GDVI); %9
GSAVI = 1.5 * ((mNIR - mG) / (mNIR + mG + 0.5)); %10
GVARI=(mG-mR)/(mG+mR); %11
MCARI=((mRE-mR)-0.2*(mRE-mG))*mRE/mR; %12
MCARI2=1.5*(2.5*(mNIR-mR)-1.3*(mNIR-mG))/... %13
    sqrt((2*mNIR+1)^2-(6*mNIR-5*sqrt(mR))-0.5);
MSAVI2 = 0.5 * (2 * (mNIR + 1) - ... %14
    sqrt((2 * mNIR + 1)^2 - 8 * (mNIR - mR)));
NDVI = (mNIR - mR) / (mNIR + mR); %15
NG = mG / (mNIR + mR + mG); %16
NNIR = mNIR / (mNIR + mR + mG); %17
NR = mR / (mNIR + mR + mG); %18
OSAVI = (mNIR - mR) / (mNIR + mR + 0.16); %19
RDVI = sqrt(NDVI * DVI); %20
RENDVI=(mNIR-mRE)/(mNIR+mRE); %21
REVARI=(mRE-mR)/(mRE+mR); %22
%RVI = mNIR / mR; %23
SAVI = 1.5 * ((mNIR - mR) / (mNIR + mR + 0.5)); %24
TCARI=3*((mRE-mR)-0.2*(mRE-mG))*mRE/mR; %25
WDRVI=(0.1*mNIR-mR)/(0.1*mNIR+mR); %26
M_O=MCARI/OSAVI; %27
T_O=TCARI/OSAVI; %28
ivs=[ARVI,DVI,EVI,GDVI,GMSAVI2,GNDVI,GOSAVI,GRDVI,GRVI,GSAVI,GVARI,
...
    MCARI,MCARI2,MSAVI2,NDVI,NG,NNIR,NR,OSAVI,RDVI,RENDVI,REVARI,...
    SAVI,TCARI,WDRVI,M_O,T_O];

```