



**DIEGO BEDIN MARIN**

**MONITORAMENTO ORBITAL  
MULTIESPECTRAL DE LAVOURAS EM  
MALHAS AMOSTRAIS DE CAFEICULTURA DE  
PRECISÃO**

**LAVRAS – MG**

**2018**

**DIEGO BEDIN MARIN**

**MONITORAMENTO ORBITAL MULTIESPECTRAL DE LAVOURAS  
EM MALHAS AMOSTRAIS DE CAFEICULTURA DE PRECISÃO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Pós-Graduação em Engenharia Agrícola, área de concentração em Sensoriamento Remoto e Geoprocessamento, para obtenção do título de Mestre.

Prof. Dr. Marcelo de Carvalho Alves  
Orientador

Prof. Dr. Edson Ampélio Pozza  
Coorientador

**LAVRAS – MG  
2018**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Marin, Diego Bedin.

Monitoramento orbital multiespectral de lavouras em malhas amostrais de cafeicultura de precisão / Diego Bedin Marin. - 2018.  
101 p.

Orientador(a): Marcelo de Carvalho Alves.

Coorientador(a): Edson Ampélio Pozza.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2018.

Bibliografia.

1. Sensoriamento remoto. 2. Índices de vegetação. 3. Variáveis bióticas e abióticas. I. Alves, Marcelo de Carvalho. II. Pozza, Edson Ampélio. III. Título.

**DIEGO BEDIN MARIN**

**MONITORAMENTO ORBITAL MULTIESPECTRAL DE LAVOURAS  
EM MALHAS AMOSTRAIS DE CAFEICULTURA DE PRECISÃO**

***MULTISPECTRAL ORBITAL MONITORING OF COFFEE  
PLANTATIONS IN SAMPLINGS GRIDS IN PRECISION COFFEE***

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Pós-Graduação em Engenharia Agrícola, área de concentração em Sensoriamento Remoto e Geoprocessamento, para obtenção do título de Mestre.

APROVADA em 19 de fevereiro de 2018.

Prof. Dr. Marcelo de Carvalho Alves

UFLA

Prof. Dr. Felipe Oliveira e Silva

UFLA

Pesquisadora Dra. Margarete Marin Lordelo Volpato

EPAMIG

Prof. Dr. Marcelo de Carvalho Alves  
Orientador

Prof. Dr. Edson Ampélio Pozza  
Coorientador

**LAVRAS – MG  
2018**

*Ao pai, ao Filho e Ao Espírito Santo  
À Santa Terezinha  
À Sant'Ana  
A Santo Expedito*

*À minha família pelo amor incondicional, valores, incentivos, compreensão,  
respeito e confiança.*

*À Andressa, por todo amor, carinho, companheirismo e por sempre acreditar  
em mim*

**DEDICO.**

## **AGRADECIMENTOS**

A Deus por ter me iluminado e me guiado para conseguir trilhar este caminho. Agradeço a Ele todos os dias por ter me concedido esta oportunidade, e colocado as pessoas certas em minha jornada.

Aos meus pais, Airton e Rosângela, a meu irmão Rafael, à minha noiva Andressa, à minha avó Ozaide, a meu sogro Milton e sogra Carmem, pelo amor incondicional, incentivos, compreensão e apoio durante esta realização profissional. Muito obrigado, sem vocês eu jamais teria conseguido, vocês sempre serão a base de tudo para mim.

Ao professor Dr. Marcelo de Carvalho Alves, pelos ensinamentos, pelo apoio, pela orientação, e principalmente, pela credibilidade depositada em mim, mesmo quando eu ainda era um desconhecido.

À Universidade Federal de Lavras (UFLA) e ao Programa de Pós-Graduação em Engenharia Agrícola pela oportunidade de realização do curso e pela contribuição à minha formação (humana e profissional).

À FAPEMIG, pela concessão da bolsa de estudos durante o período do mestrado.

Aos professores Edson Pozza, Leônida Belan e ao grupo Kaffee Gruppe (NKG), por terem me confiado os dados da mancha aureolada.

Aos membros da banca examinadora, por terem aceitado participar da avaliação deste trabalho.

Aos meus amigos do Laboratório de Geoprocessamento e Sensoriamento Remoto.

Enfim, a todos que de alguma forma contribuíram para concretização deste mestrado, meus sinceros agradecimentos.

“Todas as vitórias ocultam uma  
abdicação” (Simone de Beauvoir).

## RESUMO

O sensoriamento remoto, em conjunto com a cafeicultura de precisão, pode auxiliar o produtor a identificar as estratégias a serem adotadas, tornando a atividade mais competitiva, aumentando a produtividade e reduzindo o impacto ambiental. Face ao exposto, o objetivo do presente estudo foi avaliar o potencial do sensoriamento remoto multiespectral no monitoramento espacial e temporal da mancha aureolada (*Pseudomonas syringae* pv. *garcae*) e identificar e mapear variáveis bióticas e abióticas em uma lavoura cafeeira por meio de índices de vegetação, derivados de imagens multiespectrais Landsat 5/TM. No primeiro estudo, foi utilizado uma série temporal de 11 imagens multiespectrais Landsat 8 OLI/TIRS de janeiro a dezembro de 2014. A partir dessas imagens, calcularam-se os índices de vegetação e a temperatura de brilho. De acordo com os resultados obtidos, os índices de vegetação possibilitaram monitorar o progresso espacial e temporal da mancha aureolada na lavoura, e dentre os índices estudados, o MCARI1 apresentou os maiores valores de correlações com a incidência ( $r = 0,76$ ;  $p < 0,05$ ) e severidade ( $r = 0,52$ ;  $p < 0,05$ ) da doença. Além disso, por meio da temperatura de brilho, mapeou-se áreas com condições ideais de temperatura para ocorrência da doença. No segundo estudo, as análises de incidência de cercosporiose e infestação do bicho-mineiro nas folhas, pH, matéria orgânica e textura do solo e teores foliares de macro e micronutrientes foram correlacionadas com índices de vegetação, derivados de imagens multiespectrais Landsat 5/TM, adquiridas em datas próximas às análises das variáveis ambientais. Os índices de vegetação apresentaram distribuição espacial semelhante à distribuição espacial das variáveis agronômicas na lavoura. Houve correlação positiva dos índices com a infestação do bicho-mineiro, teor de silte e argila no solo e concentração de Mg, Cu, B e Mn nas folhas, e negativas com a incidência de cercosporiose e pH e teor de areia no solo. Com base nestes resultados, foi possível mapear e identificar as alterações na reflectância espectral dos cafeeiros, causadas por estas variáveis agronômicas.

**Palavras-chave:** Sensoriamento remoto. Índices de vegetação. Sistemas de informação geográfica. *Pseudomonas syringae* pv. *garcae*. Variáveis bióticas e abióticas. *Coffea arabica* L.

## ABSTRACT

Remote sensing, together with precision coffee production, can help the producer identify strategies to be adopted, making the activity more competitive, increasing productivity and reducing environmental impact. The objective of the present study was to evaluate the potential of multispectral remote sensing in the spatial and temporal monitoring of bacterial blight (*Pseudomonas syringae* pv. *Garcae*) and to identify and map biotic and abiotic variables in a coffee crop by means of vegetation indices, derived from Landsat 5 / TM multispectral images. In the first study, a time series of 11 Landsat 8 OLI / TIRS multispectral images was used from January to December 2014. From these images, the vegetation indices and the brightness temperature were calculated. According to the results obtained, the vegetation indices allowed to monitor the spatial and temporal progression of bacterial blight in the crop, and among the indices studied, MCARI1 presented the highest correlation values with the incidence ( $r = 0.76$ ,  $p < 0.05$ ) and severity ( $r = 0.52$ ,  $p < 0.05$ ) of the disease. In addition, by the brightness temperature, areas with temperature conditions were mapped for the occurrence of the disease. In the second study, analyzes of the incidence of brown eye spot and infestation of leaf miner, pH, organic matter and soil texture and macro and micronutrient leaf contents were correlated with vegetation indices derived from Landsat 5 / TM multispectral images, acquired on dates close to the analysis of environmental variables. The vegetation indices presented a spatial distribution similar to the spatial distribution of the agronomic variables in the crop. There was a positive correlation of the indices with infestation of leaf miner, silt and clay content in the soil and concentration of Mg, Cu, B and Mn in the leaves, and negative with the incidence of brown eye spot, pH and soil sand content. Based on these results, it was possible to map and identify the changes in the spectral reflectance of the coffee trees, caused by these agronomic variables.

**Keywords:** Remote sensing. Vegetation indices. Geographic Information System. *Pseudomonas syringae* pv. *garcae*. Biotic and abiotic variables. *Coffea arabica* L.

## SUMÁRIO

<b>PRIMEIRA PARTE .....</b>	<b>10</b>
<b>1 INTRODUÇÃO GERAL .....</b>	<b>10</b>
<b>2 REFERENCIAL TEÓRICO .....</b>	<b>12</b>
<b>2.1 O café no Sul de Minas Gerais .....</b>	<b>12</b>
<b>2.4 Sensoriamento remoto aplicado à Cafeicultura de Precisão.....</b>	<b>13</b>
<b>2.3 Índices de vegetação.....</b>	<b>17</b>
<b>2.5 Sensoriamento Remoto aplicado às doenças de plantas .....</b>	<b>19</b>
<b>REFERÊNCIAS.....</b>	<b>23</b>
<b>SEGUNDA PARTE .....</b>	<b>31</b>
<b>ARTIGO 1 - MULTISPECTRAL RADIOMETRIC MONITORING OF BACTERIAL BLIGHT OF COFFEE.....</b>	<b>31</b>
<b>ARTIGO 2 - SENSORIAMENTO REMOTO MULTIESPECTRAL NA IDENTIFICAÇÃO E MAPEAMENTO DAS VARIÁVEIS BIÓTICAS E ABIÓTICAS DO CAFÉ.....</b>	<b>71</b>

## PRIMEIRA PARTE

### 1 INTRODUÇÃO GERAL

A cafeicultura é uma atividade agrícola importante em mais de sessenta países em quatro continentes. A maioria dos países produtores estão situados na América do Sul e Central, Sudeste Asiático e África Subsaariana. Dentre esses países, o Brasil se destaca com 36% da produção mundial, equivalente a 56,1 milhões de sacas de 60 kg beneficiadas (UNITED STATES DEPARTMENT OF AGRICULTURE - USDA, 2017). A cafeicultura internacional movimenta mais de noventa bilhões de dólares anualmente para os países produtores, com os rendimentos em cascata para milhões de pequenos agricultores e trabalhadores agrícolas para os quais o café é um meio de subsistência e única fonte legal de renda (HONORATO JÚNIOR et al., 2015).

No entanto, estudos têm demonstrado que os desafios na produção de café estão se tornando cada vez mais complexos, ameaçando economias, meios de subsistências e ecossistemas inteiros nas áreas produtoras de café (JAYATHILAKA et al., 2012; RAHN et al., 2013). Em razão desses desafios, a produtividade das lavouras cafeeiras e a qualidade dos grãos estão sendo reduzidas, consideravelmente, muito em função do aumento da incidência de organismos-pragas, da severidade das doenças, estresse hídrico e o suprimento limitado de nutrientes dos solos, juntamente com a evolução lenta das tecnologias para lidar com esses desafios.

Desta forma, existe uma necessidade urgente de adoção e desenvolvimento de técnicas que auxiliem os produtores, no gerenciamento adequado das lavouras cafeeiras, de modo a elevar a produtividade e qualidade final dos grãos sem prejudicar a sustentabilidade da atividade. Nesse contexto, a cafeicultura de precisão em conjunto com técnicas de Sensoriamento Remoto pode auxiliar o cafeicultor no manejo adequado da lavoura, baseando-se na

variabilidade espacial e temporal de fatores associados ao sistema água-solo-planta, visando otimizar a aplicação de insumos e produtos fitossanitários, aumentar a produtividade e a qualidade final do produto, reduzir os custos de produção e preservar o meio ambiente. (FERRAZ et al., 2012).

A base para a aplicação das técnicas de sensoriamento remoto na agricultura está na possibilidade de avaliação da variação da quantidade de energia refletida pelas plantas ao longo do espectro eletromagnético. Variáveis bióticas e abióticas podem provocar alterações na reflectância espectral das plantas, nas regiões do visível e do infravermelho, por mudanças biofísicas e bioquímicas, como redução de biomassa, teor de clorofila e alterações nas estruturas internas das folhas, fatores esses que podem ser facilmente detectados por sensores remotos (MAHAJAN et al., 2014; BARTON, 2012).

Alguns autores (CHEMURA et al., 2016 SANTOS et al., 2014; BERNARDES et al., 2012; LAMPARELLI et al., 2012) demonstraram que a utilização do sensoriamento remoto na cafeicultura é significativa, principalmente, quando aliado à cafeicultura de precisão. Porém, há uma série de desafios que dificultam a aplicação do sensoriamento remoto na cafeicultura de precisão. Esses desafios incluem o fato de que o café é uma cultura perene, e, portanto, não apresenta ciclos fenológicos distintos que possam ser usados para sua caracterização espectral, visto que os cafeeiros não desfolham completamente. Além disso, o enfolhamento do café segue um ciclo bienal de frutificação que influencia nas aplicações do sensoriamento remoto (BERNARDES et al., 2012). Outro fator, e o mais importante, é a inter-relação das variáveis ambientais limitantes à produção do cafeeiro, que dificulta saber exatamente qual variável ambiental está influenciando na reflectância espectral e na baixa produtividade do cafeeiro (CHEMURA et al., 2016).

Diante disso, estudos aplicando o sensoriamento remoto na cafeicultura de precisão ainda são escassos. Contudo, existe um potencial elevado a ser

explorado, de forma que essa lacuna seja preenchida, garantindo o desenvolvimento da cafeicultura cada vez mais eficiente e sustentável.

Portanto, considerando a hipótese de que a reflectância espectral do cafeiro pode auxiliar a cafeicultura de precisão no gerenciamento das lavouras, o objetivo do presente estudo foi avaliar o potencial do sensoriamento remoto multiespectral no monitoramento espacial e temporal da mancha aureolada e das variáveis bióticas e abióticas em lavouras de cafeeiros (*Coffea arabica* L.).

## **2 REFERENCIAL TEÓRICO**

### **2.1 O café no Sul de Minas Gerais**

O Brasil é o maior produtor e exportador de café, detendo cerca de 36% da produção mundial e 29% das exportações, movimentando aproximadamente 6,2 bilhões de dólares por ano para o país. Essa importância econômica da cafeicultura brasileira, no âmbito internacional, também, reflete-se no mercado interno, uma vez que, o Brasil, além de ser o maior produtor e exportador de café, é o segundo mercado consumidor do mundo (UNITED STATES DEPARTMENT OF AGRICULTURE - USDA, 2017). Além disso, a cafeicultura apresenta relevante importância social como atividade geradora de empregos e fixadora de mão de obra no campo (RIBEIRO et al., 2014).

Dentre as regiões produtoras de café, o Sudeste, com os estados de Minas Gerais, Espírito Santo, Rio de Janeiro e São Paulo, destaca-se com cerca de 85% da produção nacional. Minas Gerais é o maior responsável por este cenário, destacando-se como o maior produtor no Brasil, respondendo por, aproximadamente, 54% da produção nacional (COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB, 2017).

No estado de Minas Gerais, a região Sul se destaca das demais, pois, conforme Pádua (1998), a região apresenta condições que favorecem a cultura,

tais como: fácil acesso aos grandes centros consumidores, infraestruturas adequadas e condições climáticas excelentes para o cultivo do café, além de importantes cooperativas e instituições de pesquisa e ensino que garantem uma cafeicultura de referência.

A produção nessa região, em 2017, foi de, aproximadamente, 24 milhões de sacas de 60 kg, e a estimativa de área plantada de 654,299 mil hectares, o que corresponde a 30% de área plantada de café no Brasil (COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB, 2017).

Portanto pela grande importância da cafeicultura para Brasil, sobretudo, na região do Sul de Minas Gerais, o uso de novas tecnologias que possam auxiliar no desenvolvimento da atividade cafeeira no país, torna-se indispensável, pois face ao exposto, a cafeicultura é responsável por movimentar grande parte da economia, gerando renda ao produtor, receitas cambiais e elevado número de empregos.

#### **2.4 Sensoriamento remoto aplicado à Cafeicultura de Precisão**

A agricultura de precisão se apresenta como um conjunto de tecnologias capaz de auxiliar o produtor rural a identificar as estratégias a serem adotadas para aumentar a eficácia no gerenciamento da agricultura. Inclui maximizar a rentabilidade das colheitas, tornando o agronegócio mais competitivo, quanto ao processo de globalização da economia e contribuir, assim, para o sucesso da atividade agrícola (OLIVEIRA et al., 2007; SILVA et al., 2008; CARVALHO et al., 2009).

A agricultura de precisão não é apenas uma ferramenta tecnológica, mas, sim, um conjunto de tecnologias e componentes, com base nas quais os agricultores podem formar um sistema que atenda suas necessidades e seu estilo de gestão (BATTE; EHSANI, 2006).

O termo “Cafeicultura de Precisão”, introduzido por Alves, Queiroz e Pinto (2006), pode ser entendido como o emprego das técnicas de agricultura de precisão na produção de café. De acordo com esses autores, a cafeicultura de precisão é um conjunto de técnicas que visa maximizar e otimizar a utilização de insumos na condução e manejo da lavoura em função da variabilidade espacial e temporal de fatores associados ao sistema água-solo-planta, buscando maiores produtividades, melhor qualidade, menores custos e menores aplicações de insumos e produtos fitossanitários.

Ainda, na cultura do cafeeiro, há um campo muito vasto para ser aplicada e pesquisada a agricultura de precisão, não só pela sua importância para o Brasil, mas também pelo alto grau tecnológico e valor econômico das lavouras (BALASTREIRE et al., 2001).

Além disso, o café também representa um investimento de capital em longo prazo, pois está em produção por períodos mais longos e, portanto, requer uma estratégia de monitoramento robusta, confiável e econômica para doenças, pragas, estresse hídrico, fertilidade do solo e outros estressores de culturas (CHEMURA et al., 2017).

Nesse contexto, as técnicas de sensoriamento remoto podem auxiliar a cafeicultura de precisão quanto ao gerenciamento mais eficiente das lavouras cafeeiras. De acordo com Mulla (2013), o sensoriamento remoto pode ser definido com uma tecnologia capaz de medir a quantidade de energia refletida ou emitida em diferentes regiões do espectro eletromagnético pelos campos agrícolas sem o contato físico. Esses dados são obtidos por medições de refletância de dosséis e de refletâncias dos solos, que são feitas por plataformas aéreas, plataformas orbitais ou por plataformas terrestres (AHAMED et al., 2011; MULLA et al., 2013).

Com relação às propriedades espectrais da vegetação, as folhas, quando saudáveis, apresentam refletância espectral característica, em três regiões do

espectro eletromagnético: região do visível (0,4 a 0,7 $\mu\text{m}$ ), região do infravermelho próximo (0,7 a 1,3 $\mu\text{m}$ ) e região do infravermelho médio (1,3 a 2,6 $\mu\text{m}$ ). No entanto fatores bióticos e abióticos provocam variações na reflectância espectral das folhas nessas regiões pelas mudanças biofísicas e bioquímicas, como redução de biomassa, teor de clorofila e alterações nas estruturas internas das folhas fatores, que podem ser facilmente detectadas por sensores remotos (MAHAJAN et al., 2014; BARTON, 2012).

Estudos anteriores têm mostrado que a variação da energia refletida pelas folhas das vegetações, ao longo do espectro eletromagnético, apresenta alta correlação com as propriedades biofísicas das culturas, possibilitando a identificação de setores que apresentam deficiência hídrica, ocorrência de organismos praga, deficiência de nutrientes, ou, ainda, da existência de diferentes níveis de produtividade entre uma mesma cultura (AHAMED et al., 2011; MULLA, 2013; BERNARDES et al., 2012).

Chemura et al. (2017) testaram a capacidade das bandas espetrais do visível e do infravermelho próximo, obtidos do espectro radiômetro Apogee VIS-NIR em prever o estresse hídrico nas folhas de café (*Coffee arábica L.*), usando o algoritmo *random forest*. Para isso, a reflectância foi medida em plantas de café expostas a diferentes níveis de estresse hídrico. O estudo demonstrou que é possível prever de forma confiável o estresse hídrico, nas folhas de café, usando as bandas espetrais do visível e do infravermelho próximo que correspondem à grande parte dos sensores multiespectrais disponíveis.

Lamparelli et al. (2012), com o auxílio do sensoriamento remoto hiperespectral, identificaram diferentes condições na cultura do café após a colheita. Para isso, foram geradas 38 curvas espetrais de 150 comprimentos de onda do sensor Hyperion/EO1, que, posteriormente, foram analisadas pelo algoritmo EM (*Expectation-Maximization*), considerando simulações de 2;3;4;5 clusters. Os autores mostraram que foi possível separar os cafés em cinco

diferentes grupos, consoante sua condição pós-colheita, mostrando que esta técnica pode auxiliar no planejamento agrícola de lavouras de café.

Com o objetivo de estimar a produtividade de café na mesorregião geográfica Sul/Sudeste do estado de Minas Gerais, nos anos agrícolas de 2003/2004 a 2007/2008, Rosa et al. (2010) utilizaram imagens do sensor de baixa resolução espectral MODIS e dados agrometeorológicos do modelo regional de previsão do tempo (ETA). A variável espectral de entrada do modelo agrometeorológico-espectral, índice de área foliar (IAF), usada no cálculo da produtividade máxima, foi estimada com o índice de vegetação por diferença normalizada (NDVI). O modelo agrometeorológico-espectral, baseado no modelo de Doorenbos & Kassan, foi tão eficaz para estimar a produtividade dos cafezais quanto o modelo oficial do IBGE. Além disso, foi possível espacializar a quebra de produtividade e prever 80% da produtividade final na primeira quinzena de fevereiro, antes do início da colheita.

Em um estudo para caracterizar as lavouras cafeeiras no município de Umuarama – PR, Trabaquini et al. (2011) utilizaram as bandas espetrais 3,4 e 5 de imagem Landsat 5/TM, restauradas para resolução de 15 m, na identificação visual das lavouras no município. Para o estudo do relevo, foram utilizados dados da Shuttle Radar Topography Mission (SRTM), os quais possibilitaram o conhecimento da altimetria e declividade da região. A imagem do sensor Landsat 5/TM possibilitou a execução da classificação visual e consequente identificação das lavouras cafeeiras com alta precisão. Quanto ao relevo, verificou-se que aproximadamente 99% das lavouras cafeeiras estão localizadas entre 380 e 480 metros de altitude e que 90% destas estão situadas em declividades de até 8%. Com relação aos solos, observou-se que 89% dos cafeeiros são cultivados sobre Latossolo Vermelho distrófico, de textura arenosa.

A fim de se determinar a profundidade do solo, que pode ser considerada efetiva na absorção de água pelas plantas, Santos et al. (2014) correlacionaram o

índice de vegetação EVI2 com o teor de água no solo. Os autores observaram que a profundidade de 60 cm foi a que melhor reflete o estado de água na planta.

Portanto o sensoriamento remoto aplicado à cafeicultura de precisão tem se tornado de fundamental importância à obtenção e tratamento dos dados de campo, assim como no diagnóstico da lavoura. Sendo assim, as abordagens de sensoriamento remoto na cafeicultura de precisão, combinadas com os conhecimentos tradicionais, podem contribuir para uma produção agrícola cada vez mais eficiente e sustentável.

### 2.3 Índices de vegetação

O aspecto da cobertura vegetal em determinado produto de sensoriamento remoto é resultado de um processo complexo que envolve muitos parâmetros e fatores ambientais. O que é efetivamente medido por um sensor remotamente situado, oriundo de determinada vegetação, não pode ser explicado somente pelas características intrínsecas dessa vegetação, inclui também a interferência de outras variáveis e fatores tais como a fonte de radiação, o espalhamento atmosférico, as características tanto da folha quanto do dossel, os teores de umidade, a interferência da refletância do solo, sombra, entre outros (PONZONI; SHIMABUKURO, 2009).

Diante disso, para minimizar a variabilidade causada por fatores externos, a refletância espectral da cobertura vegetal tem sido transformada e combinada em vários índices de vegetação. Esses são resultados da combinação dos valores de reflectância, em dois ou mais intervalos de comprimento de onda e estão intimamente relacionados com a quantidade e o estado da vegetação em uma dada área da superfície terrestre. Em função disso, sua característica inerente é reduzir o volume dos dados a serem analisados, dessa forma, praticamente, toda a informação referente à vegetação fica resumida a somente um valor numérico,

permitindo modelar mais facilmente os dados espectrais em conjunto com as variáveis biofísicas da vegetação (RIZZI, 2004).

A utilização dos índices de vegetação permite realçar o comportamento espectral da cobertura vegetal, que, geralmente, apresenta maiores correlações entre os valores de refletância e propriedades biofísicas da vegetação, tais como biomassa, índice de área foliar, porcentagem de cobertura vegetal, vigor da vegetação, atividade fotossintética e produtividade (EPIPHANIO et al., 1996).

Nesse contexto, Coltri et al. (2013) investigaram a relação entre índices de vegetação de imagens de alta resolução do sensor GeoEye 1 e propriedades biofísicas do café, incluindo biomassa seca. Apesar de as bandas espectrais do infravermelho próximo, verde e azul, terem apresentado correlação significativa com a biomassa seca ( $r = -0,77$ ,  $r = -0,79$  e  $r = -0,83$ ), respectivamente, as correlações mais fortes com a biomassa seca, foram apresentadas por NDVI ( $r = 0,89$ ), RVI ( $r = 0,85$ ) e GNDVI ( $r = 0,95$ ). Os autores concluíram então, que foi possível estimar o estoque de carbono das culturas de café utilizando índices de vegetação.

Rafaelli et al. (2006) avaliaram o potencial dos dados MODIS, para detectar a abrangência da área atingida, em função da resposta espectral do café antes e após a geada. Os autores verificaram que o índice de vegetação NDVI, obtido das imagens MODIS, foi eficiente para detectar a abrangência da área de geada tanto em nível nacional quanto local. Além disso, os autores constataram que imagens Landsat, quando disponíveis, foram úteis no detalhamento da dimensão do efeito da geada. Contudo, essas imagens podem apresentar elevada cobertura de nuvens, o que dificulta seu uso.

Bernardes et al. (2012), por outro lado, correlacionaram os índices de vegetação EVI e NDVI derivados do sensor MODIS, com a produção em lavouras cafeeiras no Sul do estado de Minas Gerais, no período entre 2002 e 2009. Os maiores valores de correlações entre a produtividade das lavouras e os índices de

vegetação, foram obtidas nos anos que antecederam boa produtividade, com  $r = 0,74$  para os valores mínimos de EVI e  $r = 0,68$  para os valores mínimos do NDVI. Embora as correlações não foram o suficiente, para estimar a produtividade do café, a partir de índices de vegetação, as tendências refletiram o efeito da bienalidade sobre a produtividade do cafeiro.

Volpato et al. (2013) avaliaram a relação entre o índice de vegetação espectral NDVI e as variáveis meteorológicas do balanço hídrico, em áreas cafeeiras do Sul de Minas Gerais, visando à obtenção de modelos estatísticos dessa relação. O modelo desenvolvido por esses autores demonstrou que os valores de NDVI menores que 70% podem indicar deficiência hídrica de cafeiros.

Assim, o uso de índices de vegetação na cafeicultura, permite obter informações capazes de antecipar e prever tendências de comportamento das plantas em resposta a influências de uma gama de variáveis ambientais.

## 2.5 Sensoriamento Remoto aplicado às doenças de plantas

A ocorrência de doenças de plantas é considerada um dos principais fatores limitantes à agricultura. As doenças comprometem a produção das culturas, causam grandes prejuízos aos produtores e consumidores e provocam perdas financeiras incalculáveis. Oerke e Dehne (2004) estimaram que, sem controle, doenças, pragas e ervas daninhas podem reduzir a produção mundial de culturas em 18%, 18% e 32%, respectivamente. Ainda, tal qual esses autores, apesar das atuais práticas de proteção de culturas, as perdas reais de doenças por fungos, bactérias e vírus são estimadas em 13% do potencial de produção.

As plantas respondem ao estresse causado por pragas e doenças de várias maneiras, incluindo ondulação das folhas, clorose ou necrose das partes fotosinteticamente ativas, crescimento atrofiado ou, em alguns casos, redução da

área foliar pela forte desfolha (AGGARWAL et al., 2006). No entanto, nos atuais métodos de monitoramento e identificação de doenças em plantas, a maioria dessas respostas são difíceis de quantificar e qualificar visualmente com níveis aceitáveis de precisão e rapidez (PRABHAKAR et al., 2011). Além disso, são inviáveis em áreas de cultivo extensas, pois demanda tempo excessivo de atividade e, consequentemente, aumenta o custo de produção.

Assim sendo, existe um interesse crescente em usar dados de observação terrestre para um procedimento confiável, oportuno e espacialmente explícito, para detectar doenças em plantas (SANKARAN et al., 2010; MAHLEIN et al., 2013; CHEMURA et al., 2017). O sensoriamento remoto, portanto, apresenta potencial para o monitoramento remoto contínuo da condição do café e outras culturas, oferecendo informações precisas, atualizadas e de baixo custo sobre a condição da cultura, necessárias para melhorar a proteção e a produtividade (BARET; BUIS, 2008; MULLA, 2013). Ademais, o sensoriamento remoto pode ser usado, repetidamente, para coletar as medidas da amostra de forma não destrutiva e não invasiva (PRABHAKAR et al., 2011).

O uso de técnicas de sensoriamento remoto, para a detecção do estresse das culturas, em virtude de pragas e doenças, baseia-se no pressuposto de que os estresses induzidos por esses interferem na fotossíntese e estrutura física da planta e afetam a absorção da energia incidente, alterando a reflectância das plantas ao longo do espectro eletromagnético (ZHANG et al., 2003; MULLA et al., 2013; BAJWA et al., 2017). Dependendo do sintoma, tecidos infectados apresentam mudanças, na reflectância nas regiões espectrais do visível e infravermelho, quando comparados com tecidos sadios, possibilitando sua detecção e quantificação por diferenças de reflectância (GUAN; NUTTER, 2002; WEST et al., 2003).

Diante deste conhecimento, tem sido possível estimar danos causados às culturas por patógenos, por meio de índices de vegetação calculados a partir da

combinação da energia refletida na região espectral do visível e do infravermelho (CHEMURA et al., 2016; ASHOURLOO et al., 2016; MAHLEIN et al., 2013).

Chemura et al. (2016) avaliaram o potencial de 17 índices de vegetação e bandas espetrais, derivadas do espectro radiômetro Apogee VIS-NIR para discriminar os diferentes níveis de infecção da ferrugem da folha do café (*Coffea arabica* L.) causada pelo fungo *Hemileia vastatrix*. O estudo obteve uma precisão na discriminação de 79,4% para as bandas espetrais e 82,5% para os índices de vegetação. Todavia os autores concluíram que estudos adicionais, em condições de campo, ainda, são necessários para validar a metodologia proposta.

Ashourloo et al. (2016) e Mahlein et al. (2013) desenvolveram índices específicos para doenças em plantas, o *spectral disease index* (SDI) e *spectral disease indices* (SDIs), respectivamente, e obtiveram sucesso na identificação e detecção de áreas com ocorrência de doenças. No caso do *spectral disease index* (SDI), ele mostrou alta precisão e sensibilidade na identificação dos diferentes níveis de severidade da ferrugem nas folhas de trigo. Os autores utilizaram medições de reflectância das folhas com diferentes sintomas da doença, por meio de espectro radiômetro (350-2500 nm) e observaram que comprimentos de ondas de 675 e 775 nm, combinados em forma de razão, são mais sensíveis aos sintomas da doença. Já no caso do *espectral disease índices* (SDIs), ele foi desenvolvido para detectar e discriminar folhas saudáveis de beterraba açucareira daquelas infectadas por doenças. Para isso, os autores combinaram diferentes comprimentos de ondas entre o intervalo de 450 e 950 nm e obtiveram precisão de 92%, 87%, 85% na identificação das folhas infectadas por *cercospora leaf spot*, *sugar beet rust* and *powdery mildew*, respectivamente.

Boechat et al. (2014) estudaram a resposta espectral de plantas de feijoeiro à infecção por *Sclerotinia sclerotiorum*, fungo causador do mofo-branco. Medidas de refletância espectral do dossel do feijoeiro, entre os comprimentos de ondas de 400 a 850 nm, foram tomadas aos 60, 71, 91 e 102 dias após a emergência (DAE),

no primeiro ensaio, e aos 13, 27, 34, 56, 71 e 91 DAE, no segundo. Os dados espectrais foram transformados nos índices de vegetação NDVI, GNDVI e SAVI. Os autores concluíram que a resposta espectral do feijoeiro pode ser utilizada para a detecção da ocorrência do mofo-branco e, consequentemente, como ferramenta no manejo integrado de doenças.

Os índices de vegetação derivados de imagens multiespectrais de alta resolução espacial também demonstraram precisão e correlação com doenças em plantas na cultura da cana de açúcar e eucalipto. Martins e Galo (2014) avaliaram o potencial de imagens multiespectrais RapidEye na detecção e discriminação de áreas infestadas por nematoides e *Migdolus fryanus*. A abordagem adotada se baseou na utilização das bandas espectrais originais e imagens derivadas de índices multiespectrais para distinguir áreas infestadas da cultura sadia. Por meio dos mapas temáticos resultantes foi possível observar que as imagens multiespectrais RapidEye foram apropriadas para discriminar, individualmente, as áreas infestadas por nematoides e *Migdolus fryanus*, evidenciando que o uso de combinações específicas de bandas e índices multiespectrais torna possível detectar acuradamente as áreas infestadas. Oumar e Mutanga (2014) integraram variáveis ambientais juntamente com imagens WorldView 2 para detectar e mapear danos causados por *Thaumastocoris peregrinus* em florestas de eucaliptos. As bandas da borda do vermelho e infravermelho próximo apresentaram correlações fortes de  $r = -0.60$  e  $r = -0.74$ , com os danos causados por *T. peregrinus*, respectivamente.

De forma semelhante aos estudos anteriores, porém com imagens multiespectrais obtidas a bordo de um Veículo Aéreo Não Tripulado (VANT), Garcia-Ruiz et al. (2013) realizaram a detecção e diagnóstico de áreas de pomares de citrus infestados por Huanglongbing (HLB). Para isso, os autores utilizaram seis bandas espectrais (de 530 a 900 nm) e sete índices de vegetação derivados das bandas selecionadas e aplicaram o algoritmo de classificação *support vector*

*machine (SVM) with kernel.* A classificação, obteve precisão de 85% e 11% de falsos negativos, indicando a possibilidade de utilização de imagens multiespectrais de alta resolução para a detecção de doenças na cultura do citrus.

No entanto, vale ressaltar que, apesar do potencial e da acurácia do uso do sensoriamento remoto em doenças de plantas, como mostrado anteriormente, os pesquisadores, ainda, buscam dentro do sensoriamento remoto, metodologias e ferramentas mais precisas que possam identificar os danos causados às plantas, exclusivamente, por doenças, visto que a alteração na resposta espectral das plantas, provocado por doenças, pode estar associada juntamente a uma gama de fatores ambientais, principalmente se tratando da cultura do café.

## REFERÊNCIAS

- AGGARWAL, P.K. et al. InfoCrop: a dynamic simulation model for the assessment of crop yields, losses due to pests, and environmental impact of agro-ecosystems in tropical environments. I. Model description. **Agricultural Systems**, Oxford, v. 89, n. 1, p. 1-25, 2006.
- ALVES, E. A.; QUEIROZ, D. M.; PINTO, F.A.C. Cafeicultura de precisão. In: ZAMBOLIM, L. (Ed). **Boas práticas agrícolas na produção de café**. Viçosa, MG: UFV, 2006. p. 189-223.
- AHAMED, T. et al. A review of remote sensing methods for biomass feedstock production. **Biomass and Bioenergy**, Oxford, v. 35, n. 7, p. 245502469, 2011.
- ASHOURLOO, D. et al. Developing an index for detection and identification of disease stages. **IEEE Geoscience and Remote Sensing Letters**, New York, v. 13, n. 6, p. 851-855, 2016.

BALASTREIRE, L. A. et al. Agricultura de precisão: mapeamento da produtividade de uma cultura de café. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 30., 2001, Foz do Iguaçu. **Anais eletrônicos...** Jaboticabal: SBEA, 2001. 1 CD-ROM.

BAJWA, S.G.; RUPE, J.C.; MASON, J. Soybean disease monitoring with leaf reflectance. **Remote Sensing**, Basel, v. 9, n. 2, p. 127, 2017.

BARET, F.; BUIS, S. **Estimating canopy characteristics from remote sensing observations: Review of methods and associated problems**. In: Advances in land remote Sensing. Dordrecht: Springer, 2008. 173-201 p.

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

BATTE, M.T.; EHSANI, M.R. The economics of precision guidance with auto-boom control for farmer-owned agricultural sprayers. **Computers and Electronics in Agriculture**, New York, v. 53, n. 1, p. 28-44, 2006.

BERNARDES, T. et al. Monitoring biennial bearing effect on coffee yield using MODIS remote sensing imagery. **Remote Sensing**, Basel, v. 4, n .9, p. 2492-2509, 2012.

BOECHAT, L.T. et al. Detecção do mofo-branco no feijoeiro, utilizando características espectrais. **Revista Ceres**, Viçosa, v. 61, n. 6, p. 907-915, 2014.

CARVALHO, G.R. et al. Comportamento de progêneres F4 obtidas por cruzamentos de ‘Icatu’ com ‘Catimor’. **Ciência e Agrotecnologia**, Lavras, v.33, n.1, p.47-52, 2009.

COLTRI, P.P.; ZULLO, J.; GONCALVES, R.R.V; ROMANI, L.A.S.; PINTO, H.S. Coffee Crop's Biomass and Carbon Stock Estimation With Usage of High Resolution Satellites Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, Piscataway, v. 6, n. 3, p. 1786-1795, 2013.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Acompanhamento da safra brasileira de grãos - Safra 2016/2017**. Brasília, 2017. Disponível em:  
[http://www.conab.gov.br/OlalaCMS/uploads/arquivos/17\\_09\\_21\\_17\\_00\\_05\\_cafe\\_setembro\\_2017.pdf](http://www.conab.gov.br/OlalaCMS/uploads/arquivos/17_09_21_17_00_05_cafe_setembro_2017.pdf). Acesso em: 07 nov. 2017.

CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote Sensing of Environment**, New York, v. 113, p. 893–903, 2009.

CHEMURA, A.; MUTANGA, O.; DUBE, T. Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. **Precision Agriculture**, Dordrecht, v. 18, n. 5, p. 859-881, 2016.

CHEMURA, A.; MUTANGA, O.; DUBE, T. Integrating age in the detection and mapping of incongruous patches in coffee (*Coffea arabica*) plantations using multi-temporal Landsat 8 NDVI anomalies. **International Journal of**

**Applied Earth Observation and Geoinformation**, Enschede, v. 57, p. 1-13, 2017.

EPIPHANIO, J. C. N. et al. Índices de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa Agropecuária Brasileira**, Brasília, v. 31, n. 6, p. 445-454, 1996.

FERRAZ, G. A. S. et al. Variabilidade espacial e temporal do fósforo, potássio e da produtividade de uma lavoura cafeeira. **Engenharia Agrícola**, Jaboticabal, v. 32, n. 1, p. 140-150, 2012.

JAYATHILAKA, P. M. S. et al. Spatial assessment of climate change effects on crop suitability for major plantation crops in Sri Lanka. **Regional Environmental Change**, Berlin, v. 12, n. 1, p. 55-68, 2012.

GARCIA-RUIZ, F. et al. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. **Computers and Electronics in Agriculture**, New York, v. 91, p. 106-115, 2013.

GUAN, J.; NUTTER J.R, F.W. Relationships between defoliation, leaf area index, canopy reflectance, and forage yield in the alfalfa-leaf spot pathosystem. **Computers and Electronics in Agriculture**, New York, v. 37, n. 1, p. 97-112, 2002.

HONORATO JÚNIOR, J. et al. Photosynthetic and antioxidative alterations in coffee leaves caused by epoxiconazole and pyraclostrobin sprays and Hemileia vastatrix infection. **Pesticide biochemistry and physiology**, Amsterdã, v. 123, p. 31-39, 2015.

LAMPARELLI, R.A. et al. Use of data mining and spectral profiles to differentiate condition after harvest of coffee plants. **Engenharia Agrícola**, Jaboticabal, v. 32, n. 1, p. 184-196, 2012.

MAHAJAN, G.R. et al. Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur and potassium in wheat (*Triticum aestivum* L.). **Precision agriculture**, Dordrecht, v. 15, n. 5, p. 499-522, 2014.

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

MARTINS, G.D.; GALO, M.D.L.B.T. Detecção de áreas infestadas por nematoides e *Migdolus frysyanus* em cultura canavieira a partir de imagens multiespectrais Rapideye. **Revista Brasileira de Cartografia**, Rio de Janeiro, v. 1, n. 66/2, p. 285-301, 2014.

MULLA, D.J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems engineering**, New York, v. 114, n. 4, p. 358-371, 2013.

OERKE, E.C.; DEHNE, H.W. Safeguarding production-losses in major crops and the role of crop protection. **Crop protection**, Oxford, v. 23, n. 4, p. 275-285, 2004

OLIVEIRA, E. et al. Eliminação de linhas em cafeeiros adensados por meio semimecanizado. **Ciência e Agrotecnologia**, Lavras, v.31, n.6, p.1.826-1.830, 2007.

OUMAR, Z.; MUTANGA, O. Integrating environmental variables and WorldView-2 image data to improve the prediction and mapping of *Thaumastocoris peregrinus* (bronze bug) damage in plantation forests. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdã, v. 87, p. 39-46, 2014.

PÁDUA, T.S. **Espaçamento econômico na cultura do cafeiro (*Coffea arábica* L.) - um estudo no sul de minas Gerais**. 1998. 62 p. Dissertação (Mestrado em Administração Rural) - Universidade Federal de Lavras, Lavras, 1998.

PONZONI, F.J.; SHIMABUKURO, Y.E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2009. 144 p.

PRABHAKAR, M. et al. Use of ground based hyperspectral remote sensing for detection of stress in cotton caused by leafhopper (Hemiptera: Cicadellidae). **Computers and Electronics in Agriculture**, New York, v. 79, n. 2, p. 189-198, 2011.

RAFAELLI, D.R.; MOREIRA, M.A.; FARIA, R.T. Análise do potencial de dados MODIS para monitorar o impacto de geada em nível estadual em lavouras de café. **Agricultura em São Paulo**, São Paulo, v. 53, n. 1, p. 5-15, 2006.

RAHN, E. et al. Climate change adaptation, mitigation and livelihood benefits in coffee production: where are the synergies? **Mitigation and Adaptation Strategies for Global Change**, New York, v. 19, n. 8, p. 1119-1137, 2014.

RIBEIRO, B.B. et al. Avaliação química e sensorial de blends de *Coffea canephora* Pierre e *Coffea arabica* L. **Coffee Science**, Lavras, v. 9, n. 2, p. 178-186, 2014.

RIZZI, R. **Geotecnologias em um sistema de estimativa da produção de soja: estudo de caso no Rio Grande do Sul**. 2004. 214 p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 2004.

ROSA, V.G.C. et al. Estimativa da produtividade de café com base em um modelo agrometeorológico-espectral. **Pesquisa Agropecuária Brasileira**, Brasília, v. 45, n. 12, p. 1478-14-88, 2010.

SANTOS, W.J.R. et al. Soil moisture in the root zone and its relation to plant vigor assessed by remote sensing at management scale. **Geoderma**, Amsterdã, v. 221/222, p. 91-95, 2014.

SANKARAN, S. et al. A review of advanced techniques for detecting plant diseases. **Computers and Eletronics in Agriculture**, New York, v. 72, n. 1, p. 1-13, 2010.

SILVA, F.M. et al. Variabilidade espacial de atributos químicos e produtividade da cultura do café em duas safras agrícolas. **Ciência e Agrotecnologia**, Lavras, v. 32, n. 1, p. 231-241, 2008.

TRABAQUINI, K. et al. Caracterização de lavouras cafeeiras, utilizando técnicas de geoprocessamento e sensoriamento remoto, no município de Umuarama, PR. **Ciência e Agrotecnologia**, Lavras, v. 35, n. 1, p. 35-44, 2011.

UNITED STATES DEPARTMENT OF AGRICULTURE - USDA. **Coffee: world markets and trade Foreign Agricultural Service/USDA**. Washington, 2017. Disponível em <<http://usda.mannlib.cornell.edu/usda/fas/tropprod//2010s/2016/tropprod-12-16-2016.pdf>>. Acesso em: 04 jan. 2018.

VOLPATO, M.M.L. et al. MODIS images for agrometeorological monitoring of coffee areas. **Coffee Science**, Lavras, v. 8, n. 2, p. 168 - 175, 2013.

WEST, J.S. et al. The potential of optical canopy measurement for targeted control of field crop diseases. **Annual review of Phytopathology**, Palo Alto, v. 41, n. 1, p. 593-614, 2003.

ZHANG, M. et al. Detection of stress in tomatoes induced by late blight disease in California, USA, using hyperspectral remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, v. 4, n. 4, p. 295-310, 2003.

**SEGUNDA PARTE****ARTIGO 1 - MULTISPECTRAL RADIOMETRIC MONITORING OF  
BACTERIAL BLIGHT OF COFFEE**

Diego Bedin Marin<sup>1</sup>, Marcelo de Carvalho Alves<sup>1</sup>, Edson Ampélio Pozza<sup>2</sup>,  
Leônidas Leoni Belan<sup>3</sup>, Marcelo Loran de Oliveira Freitas<sup>2</sup>

<sup>1</sup>Engineering and <sup>2</sup>Plant Pathology Departments, Federal University of Lavras,  
P.O BOX 3037, CEP 37200-000, Lavras, MG, Brazil.

<sup>3</sup>Agronomy Department, Federal University of Espírito Santo, P.O BOX, 16, CEP  
29500-000, Alegre, ES, Brazil.

Artigo preparado de acordo com as normas do periódico “*Precision  
Agriculture*”

(VERSÃO PRELIMINAR)

## Summary

Bacterial blight of coffee caused by *Pseudomonas syringae* pv. *garcae* shows great destructive potential and has caused damages in the main coffee producing regions in Brazil and worldwide. Remote sensing technologies can be used as an inexpensive and effective method to identify and monitor the disease. The present study evaluated the potential of the Landsat 8 OLI/TIRS multispectral sensor for the spatial and temporal monitoring of crops (*Coffea arabica*) affected by the bacterial blight of coffee. In this plantation, a grid sampling composed of 85 points spaced from 35 to 50 meters among themselves was demarcated. Each sampling point consisted of five plants, being four plants distributed surrounding a central plant. The analyses of the variables incidence and severity of disease were performed monthly from January to December 2014 at every sampling points and correlated with 15 vegetation indices derived from a time series of 11 multispectral images referring to each month of disease analysis. Moreover, the brightness temperature of these images was calculated in order to indicate the crop region more favorable to the occurrence of the bacterial blight of coffee. Vegetation indices highly correlated with the incidence ( $r = 0.76$ ) and severity ( $r = 0.52$ ) of the disease. The brightness temperature aided in the mapping of areas with optimal temperature conditions for the occurrence of the disease. In general, the present study demonstrated the potential of Landsat 8 OLI/TIRS images to identify and monitor crops affected by the bacterial blight of coffee.

**Key words:** *Pseudomonas syringae* pv. *garcae*. Remote sensing. Vegetation indices. Landsat 8. Coffee.

## Introduction

Coffee is one of the most important commodities in the international agricultural trade. The turnover of the international coffee growing is more than 90 billion dollars annually and its supply chain employs around half a billion people (Honorato Júnior et al. 2015). Brazil stands out for producing 33% of the 164.5 million bags of 60 kg harvested worldwide, thus being the largest producer (USDA 2017). However, several factors are responsible for reducing this production, especially plant diseases (Pozza et al. 2010).

Among the coffee diseases, the bacterial blight of coffee, whose causal agent is the bacterium *Pseudomonas syringae* pv. *garcae* (Psg) (Amaral et al. 1956; Pozza et al. 2010), has been responsible for significant crop losses in the major producing regions of Brazil (Belan et al. 2014) and countries such as Kenya (Ramos and Shavdia 1976), Ethiopia (Korobko and Wondimagegne 1997), Uganda and China (Chen 2002). This disease has destructive potential because it occurs in leaves, branches, flowers and fruits, causing defoliation, branch drying, both plagiotropic and orthotropic, besides rotting of floral rosettes, thus reducing productivity and compromising the plant architecture and its future harvests (Pozza et al. 2010; Belan et al. 2014). In addition, seeds and seedlings can transmit the pathogen and thus introduce the inoculum to epidemics in the field (Rodrigues et al. 2015; Belan et al. 2016).

According to Zoccoli et al. (2011), the bacterial blight of coffee has become limiting in regions that are cooler and exposed to the wind, being considered as one of the main diseases of coffee plantations. Due to the several spraying of bacteriostats and antibiotics in an attempt to disease control, although often ineffective, it could lead to increase in the production cost and even significant losses.

The current disease monitoring methods in plants such as the bacterial blight of coffee are impracticable in extensive farming areas. This activity requires skilled labor force, plant surveys in large crop areas, demands excessive time of activity and hence increases the production cost. Thus, there is an increasing interest in using terrestrial observation data for a reliable, timely and spatially explicit procedure for detecting plant diseases (Sankaran et al. 2010; Mahlein et al. 2012; Chemura et al. 2017). Therefore, remote sensing has great potential for continuous remote monitoring on the condition of coffee and other crops by providing accurate, updated and low-cost information on the crop condition necessary to improve protection and productivity (Mahlein et al. 2012; Mulla 2013). Moreover and perhaps more importantly, remote sensing in precision agriculture can reduce the environmental impact and application costs of plant health products, since disease control can be performed in advance and more directed (Sankaran et al. 2010; Mahlein et al. 2012; Barbedo 2013; Chemura et al. 2016).

The use of remote sensing applied to plant diseases has been possible because infected plants show different spectral reflectance when compared to healthy plants. The physiological reaction of a diseased plant will result in altered reflectance in the visible, near-and mid-infrared spectral regions due to lower chlorophyll content, leaf temperature and altered internal structure of leaves (Zhang et al. 2003).

Based on this knowledge, Chemura et al. (2016) assessment the potential of vegetation indices and spectral bands derived from the Sentinel 2 sensor in order to discriminate different infection levels of coffee leaf rust (*Hemileia vastatrix*) in crops. These authors reported 79.4% accuracy in rust discrimination using spectral bands and 82.5% by using vegetation indices. Similarly, Mahlein et al. (2013) developed the specific spectral disease indices (SDIs) to detect and discriminate healthy leaves of sugar beet from those infected with Cercospora leaf

spot, sugar beet rust and powdery mildew and obtained accuracy of 89%, 92%, 87%, 85%, respectively. Other studies have also demonstrated the potential of remote sensing applied to plant diseases, including wheat leaf rust infection (Ashourloo et al. 2016), eucalyptus infested by *Thaumastocoris peregrinus* (Oumar and Mutanga 2014), infested by olive fruit fly (Moscetti et al. 2015), rice sheath blight (Qin and Zhang 2005) and late blight disease tomato (Zhang et al. 2003).

However, these studies did not evaluate the interaction between the spectral reflectance of the diseased plants throughout the year and the environmental variables. In addition, they did not use a time series of images evaluating this interaction.

Based on the above, the aim of the present study was to evaluate the potential of the Landsat 8 OLI/TIRS multispectral sensor for the spatial and temporal monitoring of crops (*Coffea arabica*) affected by the bacterial blight of coffee.

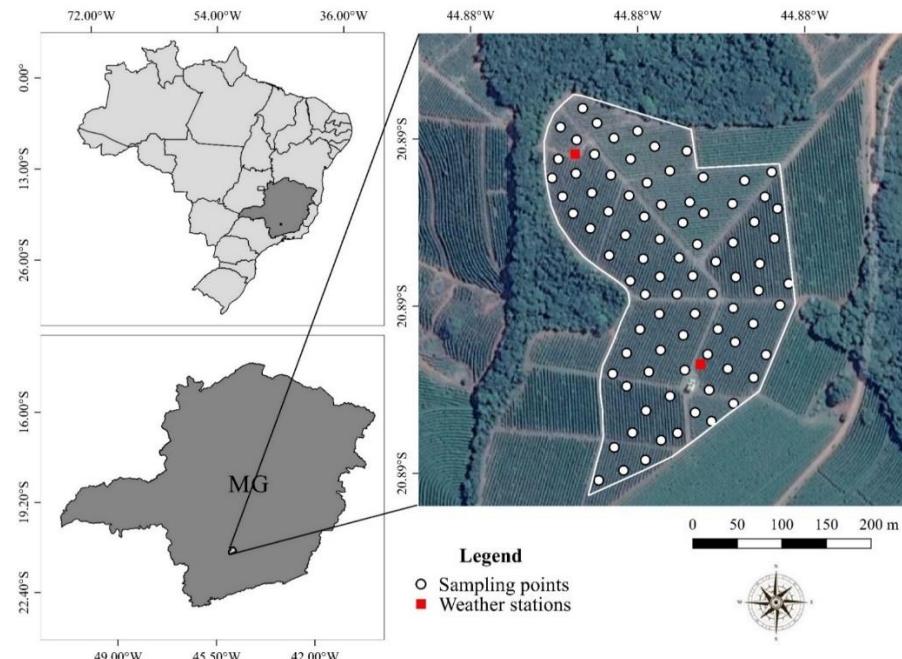
## **Material and Methods**

The experiment was performed in a crop at the Neuman Kaffee Gruppe farm (NKG), located in the municipality of Santo Antônio do Amparo, MG, Brazil, geographical coordinates 20°53'23.7" S and 44°52'56.9" W, and 1140 m altitude. This crop occupies a total area of 7.65 ha cultivated with coffee plantations of the cultivar Catucaí Amarelo 2SL aged four years, planted with 3.7 m spacing between lines and 0.7 m between plants, totaling 3,862 plants.ha<sup>-1</sup> (Fig. 1).

In this plantation, a grid sampling composed of 85 points spaced from 35 to 50 meters among themselves was demarcated. Each sampling point consisted of five plants, being four plants distributed surrounding a central plant. The

georeferencing of the points was performed with GPS TRIMBLE 4600 LS® and Leica TC600 Total Station.

In order to measure the average temperature, average wind speed and rainfall, two Campbell Scientific® weather stations, models CR10X and CR1000, were installed at altitudes 1,130 and 1,145 m, respectively.



**Fig. 1** Geographical location of the experimental plot and design representing the grid sampling with 85 distant sample points between 35 and 50 m apart. Each georeferenced point on the map consists of five coffee plantations. The red squares represent Campbell Scientific CR10X and CR1000 weather stations. Santo Antônio do Amparo, MG, Brazil.

### Monitoring disease and recording meteorological data

The records of the meteorological variables were sampled once per hour throughout the year 2014. Subsequently, the monthly average of the variables

average temperature, rainfall and average wind speed of weather stations were calculated.

Monthly assessments of the variables incidence and severity of the plant disease were performed, and the foliage of five plants from each sampling point were collected. The incidence of diseased plants was obtained by counting the number of symptomatic plants for a total of five and calculating the percentage of diseased plants per point. In order to obtain the severity, each of the five plants was evaluated using the scale proposed by Ito et al. (2008), with modifications, assigning grades from 1 to 5, being: 1 = absence of lesions; 2 = 1% to 15% of diseased leaves; 3 = 16% to 30% of diseased leaves; 4 = 31% to 45% of diseased leaves and 5 = above 45% of diseased leaves and death of pointers and/or the upper third of the plant. To estimate the foliage of plants, the scale proposed by Boldini (2001) was used.

The severity and foliage grades were converted to rate of lesioned leaf area and foliage per plant, respectively. Subsequently, the average of the five plants evaluated per sampling point was calculated.

In order to quantify the crop yield, the fruits of five plants from each sampling point were harvested manually in June 2014 and 2015. *In natura* fruits were weighed and the average yield (kg/plant) was calculated.

### **Obtaining spectral data**

The Landsat 8 OLI/TIRS Collection 1 Level-2 (Table 1) satellite images obtained from January to December 2014 were used for the calculation of vegetation indices and spectral signature, except for the month of March because the images contained clouds. These images were acquired from the United States Geological Survey (USGS) at reflectance values and with 6S atmospheric correction. In this way, the images were not pre-processed.

**Table 1** Landsat 8 OLI / TIRS satellite features.

Band Description	Band width ( $\mu\text{m}$ )	Spatial Resolution (m)
1 - Coastal Aerosol	0,43 a 0,45	30
2 - Blue	0,45 a 0,51	30
3 - Green	0,53 a 0,59	30
4 - Red	0,64 a 0,67	30
5 - Near-Infrared	0,85 a 0,88	30
6 - Short Wavelength Infrared 1	1,57 a 1,65	30
7 - Short Wavelength Infrared 2	2,11 a 2,29	30
8 - Panchromatic	0,50 a 0,68	15
9 - Cirrus	1,36 a 1,38	30
10 - Thermal Infrared Sensor 1	10,60 a 11,69	100
11 - Thermal Infrared Sensor 1	11,50 a 12,51	100

For the calculation of brightness temperature, the Landsat 8 OLI/TIRS Collection 1 Level-1 images were used. However, before being calculated, it was necessary to convert the brightness temperature values into gray levels (GL) or digital numbers (DN) of the images to radiance values, being used the methodology proposed by USGS (2017) (Equation 1).

$$L_{\lambda} = M_L * Q_{\text{cal}} + A_L \quad (1)$$

Where  $L_{\lambda}$  is the spectral radiance at the sensor aperture;  $M_L$  is the scaling factor of the specific band;  $Q_{\text{cal}}$  is quantized and calibrated standard product pixel values; and  $A_L$  is the additive scaling factor of the specific band.

The conversion from radiance values to the brightness temperature (Equation 2) was performed according to USGS (2017).

$$T_B = \frac{K_1}{\ln[(K_2/L_{\lambda}) + 1]} \quad (2)$$

Where  $T_B$  is the brightness temperature;  $K_1$  is the calibration constant for the thermal band 1;  $K_2$  is the calibration constant for thermal band 2; and  $L_\lambda$  is the spectral radiance at the sensor aperture.

### **Vegetation indices**

The vegetation indices (Table 2) were calculated based on the combination of spectral bands of the images described above.

### **Topography of the crop**

In order to characterize the relief of the study plot, aspect-slope maps were generated from the altimetry of Shuttle Radar Topography Mission (SRTM).

To obtain the topographic map, the digital elevation model (DEM) with 30 m spatial resolution was used, derived from the SRTM and provided by the USGS. From the DEM, the aspect-slope maps were obtained.

The criteria used to classify aspect maps were proposed by De Biase (1970), being N – NE ( $0^\circ - 45^\circ$ ), NE – E ( $45^\circ - 90^\circ$ ), E – SE ( $90^\circ - 135^\circ$ ), SE – S ( $135^\circ - 180^\circ$ ), S – SW ( $180^\circ - 225^\circ$ ), SW – W ( $225^\circ - 270^\circ$ ), W – NW ( $270^\circ - 315^\circ$ ), NW – N ( $315^\circ - 360^\circ$ ).

### **Correlation analysis**

The monthly data on the incidence and severity of the bacterial blight of coffee, coffee foliage and vegetation indices values calculated for the 85 pixels for every 85 sample points were submitted to Pearson correlation analysis ( $p=0.05\%$ ).

**Table 2** Vegetation indices obtained from the reflectance of the multispectral bands of Landsat 8 OLI / TIRS images.

Vegetation indices	Formula	Source
SIFI	$\frac{\rho_{\text{nir}} - \rho_{\text{blue}}}{\rho_{\text{nir}} + \rho_{\text{red}}}$	Peñuelas et al. (1995)
GARI	$\frac{\rho_{\text{nir}} - [\rho_{\text{green}} - 1.7(\rho_{\text{blue}} - \rho_{\text{red}})]}{[\rho_{\text{nir}} + (\rho_{\text{green}} - 1.7(\rho_{\text{blue}} - \rho_{\text{red}})]}$	Gitelson et al. (1996)
TVI	$0.5[120(\rho_{\text{nir}} - \rho_{\text{green}}) - 200(\rho_{\text{red}} - \rho_{\text{green}})]$	Broge e Leblanc (2001)
MCARI1	$1.2[2.5(\rho_{\text{nir}} - \rho_{\text{green}}) - 1.3(\rho_{\text{nir}} - \rho_{\text{green}})]$	Haboudane et al. (2004)
MCARI2	$\frac{1.2[2.5(\rho_{\text{nir}} - \rho_{\text{red}}) - 1.3(\rho_{\text{nir}} - \rho_{\text{green}})]}{\sqrt{2(\rho_{\text{nir}} + 1)^2 - 0.5} - 6(\rho_{\text{nir}} - 5\sqrt{\rho_{\text{red}}})}}$	Haboudane et al. (2004)
MSAVI	$0.5[2\rho_{\text{nir}} + 1 - \sqrt{(2\rho_{\text{nir}} + 1)^2 - 8(\rho_{\text{nir}} - \rho_{\text{red}})}]$	Qi et al. (1994)
NDWI	$\frac{\rho_{\text{nir}} - \rho_{\text{swir1}}}{\rho_{\text{nir}} + \rho_{\text{swir1}}}$	Gao (1996)
NDVI	$\frac{\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}}}$	Rouse et al. (1973)
SAVI	$\frac{(1 + L)\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}} + L}$	Huete (1988)
GNDVI	$\frac{\rho_{\text{nir}} - \rho_{\text{green}}}{\rho_{\text{nir}} + \rho_{\text{green}}}$	Gitelson et al. (1996)
MTVI1	$1.2[1.2(\rho_{\text{nir}} - \rho_{\text{green}}) - 2.5(\rho_{\text{red}} - \rho_{\text{green}})]$	Haboudane et al. (2004)
MTVI2	$\frac{1.5[1(\rho_{\text{nir}} - \rho_{\text{green}}) - 2.5(\rho_{\text{red}} - \rho_{\text{green}})]}{\sqrt{[(2\rho_{\text{nir}} + 1)^2 - (6\rho_{\text{nir}} - 5\sqrt{\rho_{\text{red}}}) - 0.5]}}$	Haboudane et al. (2004)
RDVI	$\sqrt{\frac{\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}}}}$	Roujean e Breon (1995)
MSR	$\frac{\left(\frac{\rho_{\text{nir}}}{\rho_{\text{red}}}\right) - 1}{\sqrt{\left(\frac{\rho_{\text{nir}}}{\rho_{\text{red}}}\right)} + 1}$	Chen (1996)
SR	$\frac{\rho_{\text{nir}}}{\rho_{\text{red}}}$	Birth e McVey (1968)

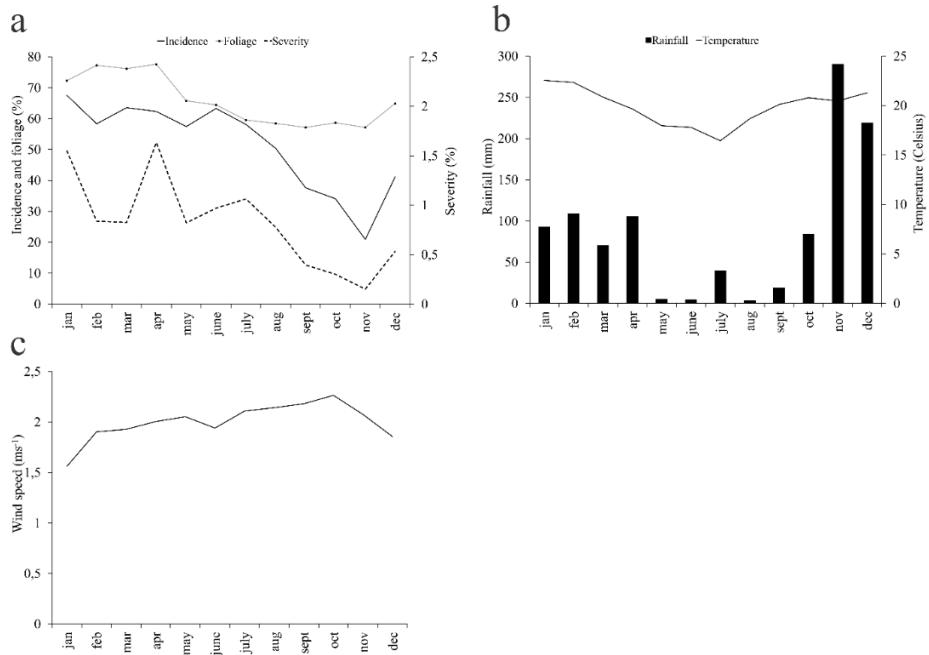
### **Spectral signature**

Spectral signature was calculated based on reflectance of the spectral bands of blue, green, red, near- and mid-infrared in an area in the northwest region and another in the southeast, with presence/higher values and absence/lower values of incidence and severity of the disease, respectively. In this respect, an area of 3x3 pixels was established in the northwest region and another in the southeast of the crop. Once the spectral signature of each image was obtained, the average spectral reflectance of these images was calculated in all the bands.

## **Results and Discussion**

### **Temporal distribution of disease, foliage and meteorological variables**

The bacterial blight of coffee occurred during the entire assessment period. Between January and June, there was the highest values of disease incidence, reaching 68% in January and averaging 62% during this period (Fig. 2). From June, the disease incidence was reduced to 21% in November. The temporal progress of the disease severity was similar to the incidence variable. The highest values occurred between January and June, with peaks of 1.55% in January and 1.63% in April, with reduction of severity values from July up to the lowest value (0.15%) in November (Fig. 2).



**Fig. 2** Incidence (%) and severity (%) of the bacterial blight of coffee (*Pseudomonas syringae* pv. *garcae*) and the foliage (%) over time in coffee plantations (*Coffea arabica*) (a) of the rainfall (mm), average temperature ( $^{\circ}\text{C}$ ) (b) and wind speed ( $\text{m.s}^{-1}$ ) (c) in the experimental area from January to December 2014. Santo Antônio do Amparo, MG, Brazil.

The highest values of foliage occurred between January and April, averaging 76%. However, there was defoliation after June and the foliage level decreased by up to 57% in November (Fig. 2). This defoliation may be associated with leaf fall caused during the harvest performed in June.

The average temperature in the crop ranged from 22.5 to 16.5  $^{\circ}\text{C}$ . However, in the months of higher incidence and severity of the disease (January and/or April), the average temperature varied between 22.5  $^{\circ}\text{C}$  and 20  $^{\circ}\text{C}$ . The total annual rainfall in the crop was 1044 mm, and during the rainy season between

January and April (average monthly rainfall of 94.5 mm) was also the season with the highest intensity of the bacterial blight of coffee (Fig. 2).

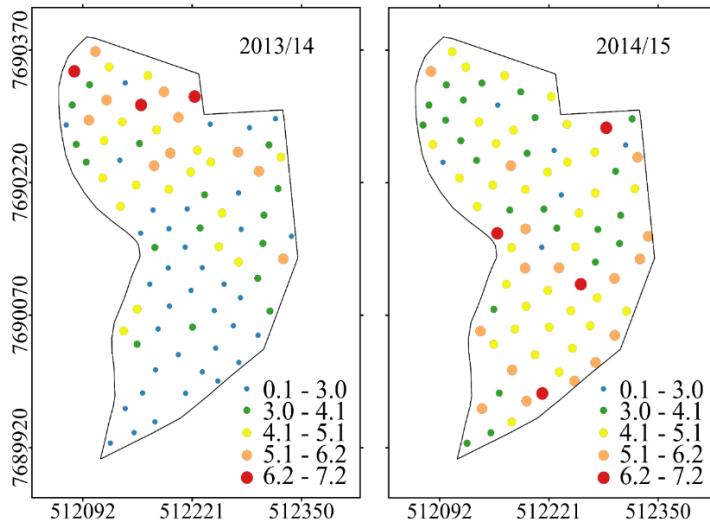
The annual average wind speed was 2 m/s (Fig. 2). This constant wind speed may have facilitated the occurrence of the bacterial blight of coffee throughout 2014.

Some authors (Ithiru et al. 2013; Zoccoli et al. 2011) reported the influence of meteorological variables on the occurrence and progression of bacterial blight of coffee, however, there is no consensus on the values of temperature and duration of leaf wetting favorable to the infection, nor its interaction. According to Sera (2001), only empirical characteristics such as low temperatures and high regions with predominant strong winds are usually described.

### **Spatial distribution of yield, disease and foliage in the crop**

The spatial distribution of coffee yield in the 2013/14 harvest averaged between 2.23 kg.plant<sup>-1</sup> in the southeast region and 4.9 kg.plant<sup>-1</sup> in the northwest region. In the 2014/2015 harvest, productivity was similar in both regions, since yield in the southeast region was 4.17 kg.plant<sup>-1</sup> and 4.22 kg.plant<sup>-1</sup> in the northwest region (Fig. 3).

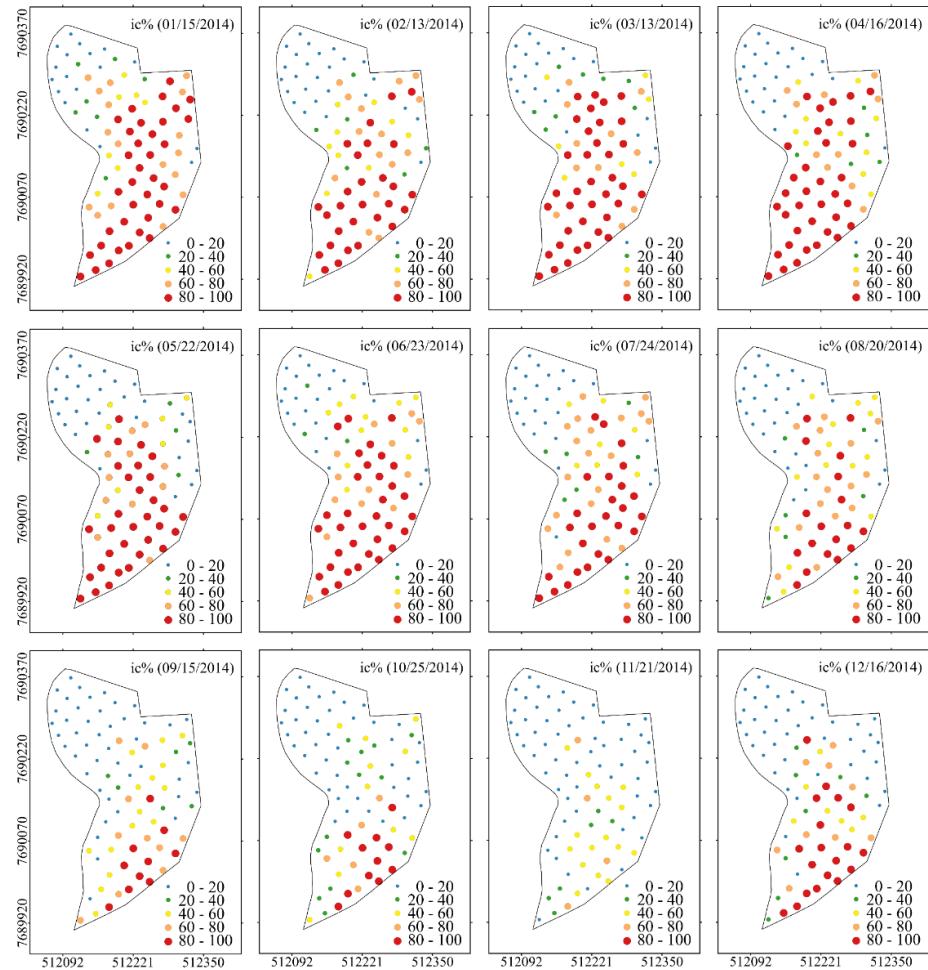
Although the 2014/2015 harvest had equivalent yield between the northwest and southeast regions of the crop, a reduction in the yield of the south region was expected due to the intensity of the bacterial blight of coffee in plants from this region, since it causes defoliation, branch drying and rotting of floral rosettes, thus reducing plant yield and crop productivity (Rodrigues et al. 2017; Belan et al. 2014; Zoccoli et al. 2011; Pozza et al. 2010).



**Fig. 3** Quantile maps of the spatial distribution of average yield in  $\text{kg.plants}^{-1}$  at coffee plantations (*Coffea arabica*) located in the municipality of Santo Antônio do Amparo, MG, Brazil, in 2013/2014 and 2014/2015 harvests.

Rodrigues et al. (2013) and Zoccoli et al. (2011) stated that productivity losses due to the bacterial blight of coffee are significant, but did not report such losses numerically.

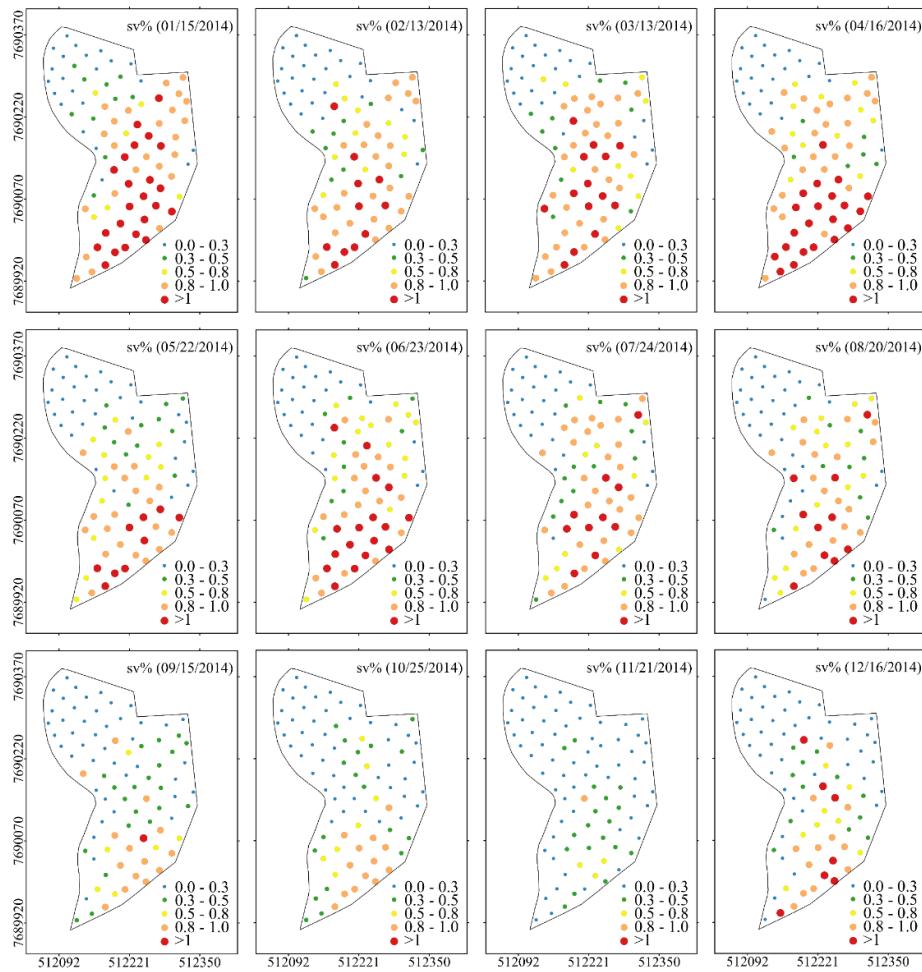
The southeast face of the crop showed outbreaks of the disease throughout the study period. In the months with the highest incidence of the disease (January and April), the rate of diseased plants in the southeast region reached 100%. In the northwest, the maximum rate of diseased plants was 12%, showing absence of the disease in the months of least incidence (October and November) (Fig. 4).



**Fig. 4** Quantile maps of the spatial distribution of incidence of the bacterial blight of coffee (*Pseudomonas syringae* pv. *garcae*) at coffee plantations (*Coffea arabica*) located in the municipality of Santo Antônio do Amparo, MG, Brazil, from January to December 2014.  
\*ic% = Incidence (%).

The spatial distribution of the bacterial blight of coffee showed a spatial distribution pattern similar to the disease. In the months with greater disease severity (January and April), the plants from the southeast region showed a disease severity above 1%. On the other hand, the severity values in the northwest region

were 0% in the months of least severity (October and November), since the plants from this region did not show disease in this period (Fig. 5).



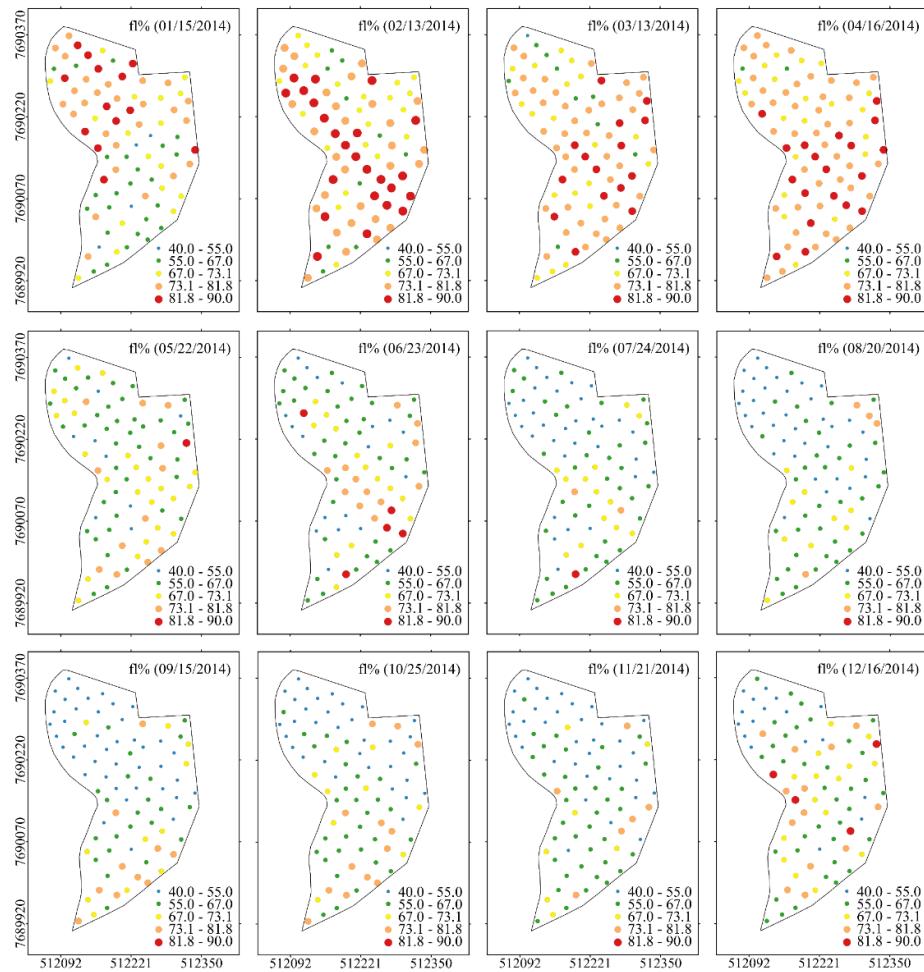
**Fig. 5** Quantile maps of the spatial distribution of the bacterial blight severity (*Pseudomonas syringae* pv. *garcae*) at coffee plantations (*Coffea arabica*) located in the municipality of Santo Antônio do Amparo, MG, Brazil, from January to December 2014.

\*sv% = Severity (%).

The spatial distribution in foci is characteristic of bacterial causal agents. Such distribution pattern has already been reported for bacterial blight of coffee in a seedling nursery (Belan et al., 2014), and bacterial leaf spots from other cultures, e.g., hazelnut blight (*Xanthomonas arboricola* pv. *corylina*), Pierce's disease of grape (*Xylella fastidiosa*) and onion bacterial blight (*Xanthomonas axonopodis* pv. *allii*) (Roumagnac et al. 2004; Lamichhane et al. 2013; Park et al. 2011).

The spatial distribution of plant foliage in the crop was homogeneous until harvesting in June (Fig. 6). From the harvest, the southeast region of the crop, with the highest incidence and severity of the bacterial blight of coffee (Figures 4 and 5), showed plants with higher foliage (71% on average) in relation to plants from the northwest region (49% on average), with lower occurrence of the disease.

The higher foliage of the southeast region after harvest may be associated with lower plant yield in this region due to the higher occurrence of the disease (Fig. 3,4 and 5). Thereby, the foliage was greater because there was less defoliation caused by the harvest. Moreover, due to lower yields, the plants from this region focused their physiology to vegetative growth in detriment of reproductive functions, preserving greater foliage for a longer period.

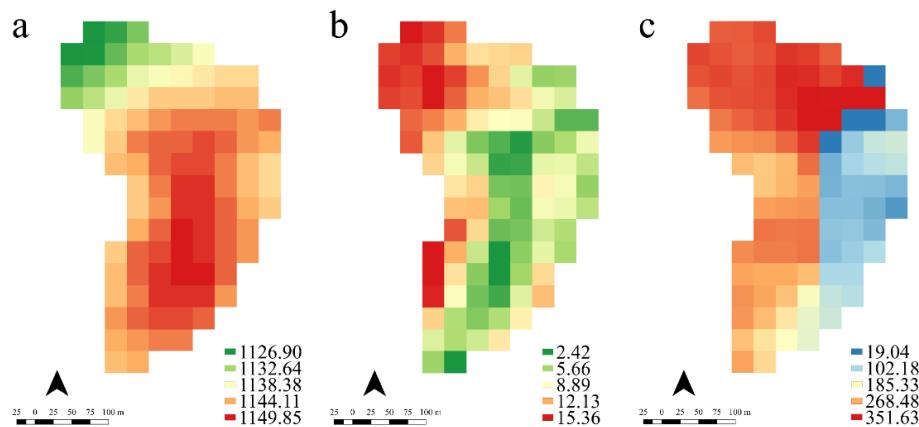


**Fig. 6** Quantile maps of the spatial distribution of foliage at coffee plantations (*Coffea arabica*) located in the municipality of Santo Antônio do Amparo, MG, Brazil, from January to December 2014. \*fl% = Foliage (%).

### Topography of the crop

The altitude of the experimental area varied from 1126 to 1149 m, with the highest values of altitudes located in the southern and central part of the terrain, being regions with higher incidence and severity of the disease (Fig. 4 and

5). The southern and central regions of the terrain also showed the lowest slope values (5.7% on average), forming a plateau (Fig. 7).



**Fig. 7** Maps of elevation (m) (a), slope (%) (b) and aspect (%) (c) at coffee plantations (*Coffea arabica*) located in Santo Antônio do Amparo, MG, Brazil.

The relationship between elevation, slope and bacterial blight of coffee was also reported by Zoccoli et al. (2011). According to these authors, the favorable regions for the incidence of bacterial blight of coffee are located in regions above 1000 m, where there are crops established on plateaus or terrains with sharp slope exposed to strong winds. These information presented by Zoccoli et al. (2011) corroborate the results of the present study. Under these conditions, the wind, besides harming the plant leaves, providing sites for bacterial infection, it also increases the intensity of the bacterial blight of coffee in the field and aids in the disease spreading by carrying the aerosols containing bacterial cells to the neighboring plants (Pozza et al. 2010, Rodrigues et al. 2013). In this context, the southeast region of the crop shows more favorable conditions to the bacterial blight of coffee, since it is situated at an altitude higher than the northwest region and exposed to higher speed winds, being the annual average wind speed in the

CR10X (northernmost)  $1.97 \text{ m.s}^{-1}$  and  $2.02 \text{ m.s}^{-1}$  in the CR1000 station (to the south).

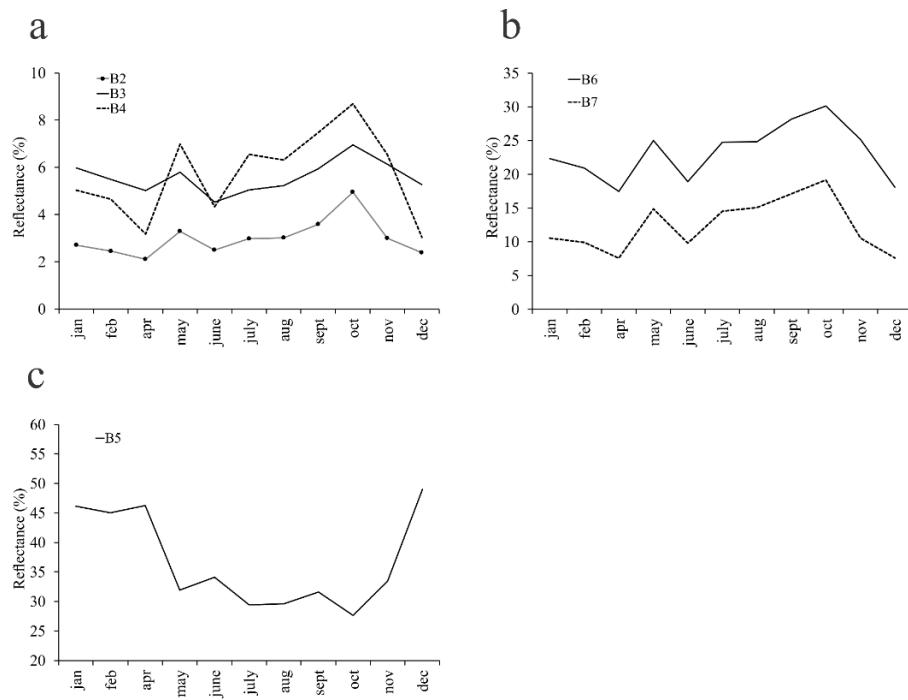
Regarding the aspect of the terrain, the north part of the crop is greatly exposed to solar radiation throughout the year in relation to the south part of the terrain, since the north-west faces ( $315^\circ$ - $360^\circ$ ) are exposed to a higher direct incidence of radiation when compared to the southwest-south faces ( $225^\circ$ - $270^\circ$ ), according to De Biase (1970). Thus, the annual temperature in the south ( $19.1^\circ\text{C}$ ) was lower in relation to the north region of the crop ( $20^\circ\text{C}$ ), which may have facilitated greater development of the bacterial blight of coffee in the south region, since low or mild temperatures are described as favorable to disease (Ito et al. 2008; Ithiru et al. 2013).

### Average reflectance time series

In general, the reflectance in the visible (B2, B3 and B4) and mid-infrared spectral region (B6 and B7) (Fig. 8) were inversely proportional to the incidence and severity of the bacterial blight of coffee, since the reflectance values in these spectral regions were lower in the months with higher incidence (Fig. 4 and 5). In contrast, it was directly proportional in the near-infrared (B5) spectral region.

The average reflectance of pixels along the electromagnetic spectrum followed the crop cycle of the culture. For the reflectance in the near-infrared region, the highest values were found between January and April, periods of higher rainfall and therefore greater vegetative vigor and foliage of coffee. The lowest reflectance values for this region occurred between June and August because the dry season provide lower vegetative vigor, besides defoliation caused by the crop. However, the reflectance in the visible and mid-infrared regions was the contrary in relation to the near-infrared values, since the higher the vegetative vigor and the coffee leaf growth, the lower the reflectance in the visible and mid-

infrared regions due to the increase of photosynthetic activity and water content in the leaves.



**Fig. 8** Average reflectance in the pixels of Landsat 8 OLI/TIS images in the spectral regions of visible, band 2 (B2), band 3 (B3) and band 4 (B4) (a), mid-infrared, band 6 (B6) and band 7 (B7) (b) and near-infrared, band 5 (B5) (c), from January to December 2014. Santo Antônio do Amparo, MG, Brazil.

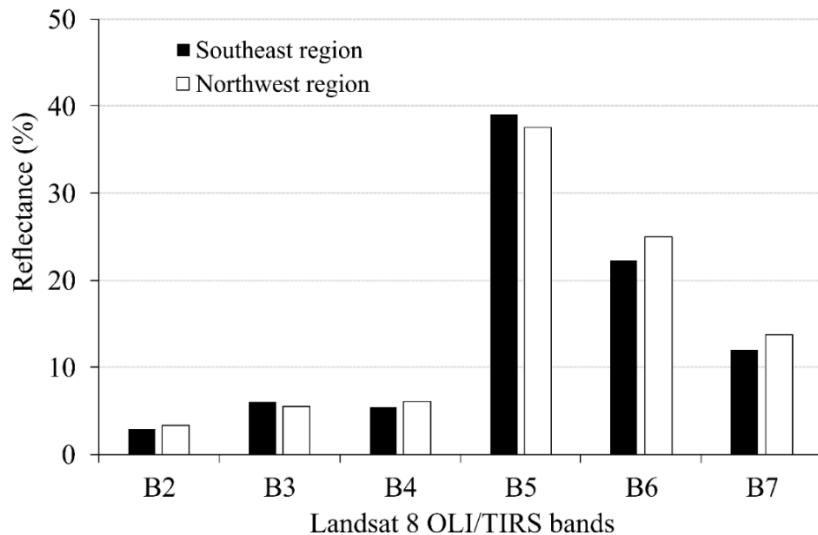
The direct relationship between coffee cycle and reflectance in the near-infrared region was also evidenced by Bispo (2013). Based on a time series of 163 images of the near-infrared band to map coffee areas in the municipality of Monte Santos de Minas, MG, Brazil, the author observed that the highest reflectance values occurred at the time of the highest rainfall, while the lowest values were in the dry season and postharvest.

### Spectral signature

The reflectance in the near-infrared spectral region (B5) at the higher occurrence area of the disease was higher in relation to the lower occurrence area (Fig. 4). In contrast, the reflectance in the visible spectral region (B2 and B4), except for B3, and the mid-infrared region (B5 and B6) was lower in the higher occurrence area of the disease (Fig. 9).

One of the characteristics of the spectral reflectance of coffee, and the vegetation in general, is the low reflectance and transmittance in visible spectral regions due to the strong absorption by photosynthetic pigments of plants such as chlorophyll and anthocyanins (Chappelle et al. 1992; Pinter et al. 2003). In contrast, the reflectance of plants in the near-infrared spectral region is high, due to the interaction of energy with the internal structures of leaves (spongy palisade parenchyma) and canopy structure (Slaton et al. 2001). For the mid-infrared region, the reflectance is controlled by the water content in the plant tissue; therefore, it is relatively high for vigorous vegetation, being reduced according to the dehydration of tissues (Pinter et al. 2003).

In this context, the difference between the reflectance along the electromagnetic spectrum in the higher and lower intensity areas of the disease can be explained by the higher amount of leaves in plants with the higher intensity of the disease (Fig. 4). According to Ahamed et al. (2011), the higher the number of leaves in the plants, the lower the visible reflectance and the greater the near-infrared. Moreover, the reduced number of leaves decreases the water content in the plant, provoking greater reflectance in the mid-infrared region (Moreira et al. 2004).



**Fig. 9** Average reflectance (%) of the Landsat 8 OLI/TIRS images in the visible (B2, B3 and B4), near-infrared (B5) and mid-infrared (B6 and B7) regions at the highest and lowest occurrence area of the bacterial blight of coffee in the crop of *Coffea arabica* located in the municipality of Santo Antônio do Amparo, MG, Brazil, throughout the year 2014.

The identification of diseases in cultures based on the difference of spectral reflectance in the visible, mid- and near-infrared regions has shown great efficacy and accuracy. According to previous studies in other cultures with other diseases (Ashourloo et al. 2016; Huang et al. 2014; Boechat et al. 2014; Martins and Galo, 2014; Chemura et al., 2017), infected plants show changes in the internal structures of their leaves, thus altering the reflectance in the aforementioned spectral regions. According to these authors, the spectral signature, besides showing high potential, can satisfactorily replace the current methods of monitoring and identification of areas with insect attack or disease occurrence.

**Correlation analysis between the variables incidence and severity of the bacterial blight of coffee and coffee foliage with the vegetation indices**

The correlation between the disease incidence variable and the vegetation indices was positive for all indices and in all months, from the lower to higher months of disease incidence (Table 3). The MCARI1 vegetation indice showed higher correlation coefficient values with the disease incidence variable. The highest correlation values for this indice occurred in the months of June ( $r= 0.72$ ), July ( $r= 0.76$ ) and August ( $r= 0.70$ ), while the lowest correlation values were showed by GARI in the months of November and December (not significant correlations).

**Table 3** Pearson correlation coefficients between the variables incidence (%) of the bacterial blight of coffee (*Pseudomonas syringae* pv. *garcae*) in coffee plantations (*Coffea arabica*) and vegetation indices. Santo Antônio do Amparo, MG, Brazil, January to December 2014.

Vegetation indices	Jan	Feb	Apr	May	June	July	Aug	Sept	Oct	Nov	Dec	Annual average
SAVI	0,35	0,29	0,32	0,64	0,70	0,74	0,65	0,54	0,44	0,44	0,48	0,51
TVI	0,44	0,46	0,34	0,65	0,70	0,75	0,65	0,63	0,43	0,48	0,53	0,55
MCARI1	0,59	0,55	0,34	0,64	0,72	0,76	0,70	0,63	0,54	0,48	0,53	0,59
MCARI2	0,29	0,35	0,29	0,62	0,67	0,72	0,61	0,51	0,38	0,46	0,51	0,49
MTVI1	0,41	0,44	0,32	0,65	0,70	0,75	0,64	0,55	0,40	0,48	0,53	0,53
MTVI2	0,32	0,37	0,31	0,66	0,69	0,73	0,61	0,51	0,36	0,46	0,51	0,50
GNDVI	0,27	0,27	0,28	0,39	0,64	0,69	0,59	0,49	0,51	0,21	0,31	0,42
MSAVI	0,36	0,38	0,38	0,53	0,65	0,69	0,62	0,49	0,41	0,25	0,36	0,47
NDVI	0,33	0,37	0,35	0,35	0,59	0,64	0,54	0,45	0,38	0,24	0,26	0,41
NDWI	0,31	0,35	0,38	0,22	0,69	0,74	0,48	0,49	0,34	0,29	0,25	0,41
RDVI	0,33	0,36	0,36	0,34	0,59	0,64	0,54	0,45	0,38	0,28	0,26	0,41
SR	0,38	0,40	0,30	0,38	0,57	0,62	0,52	0,44	0,37	0,21	0,30	0,41
SICI	0,31	0,35	0,32	0,59	0,64	0,68	0,60	0,49	0,48	0,25	0,36	0,46
MSR	0,37	0,39	0,32	0,37	0,57	0,62	0,53	0,45	0,37	0,24	0,29	0,41
GARI	0,32	0,34	0,32	0,29	0,56	0,59	0,50	0,43	0,32	ns	ns	0,40

ns= not significant

The high foliage index of plants (Fig. 6) from January to April may have contributed to the lower correlation values between the disease incidence variable and the vegetation indices in this period, since plants with a high number of foliage show a homogeneous and closed canopy, precluding the identification of diseased plants by sensors. even though in months with the highest incidence of the disease. However, from June to December, the foliage index decreases and the canopy becomes less homogeneous and closed, allowing greater precision and accuracy of vegetation indices to identify diseased plants, despite being the period of least incidence of the disease.

For the variable severity of the bacterial blight of coffee, the correlation with the vegetation indices was also positive for all indices (Table 4). However, from January to May, there was no correlation between these variables. Analogously to the disease incidence variable, the MCARI1 vegetation indice showed the highest correlation coefficient values with the disease severity variable in June ( $r= 0.52$ ). July ( $r= 0.51$ ) and August ( $r=0.47$ ), while the lowest values were showed by GARI in the months of November and December (not significant correlations).

The high foliage index from January to May may also have been responsible for not having significant correlations in these months between the vegetation indices and the disease severity variable, despite being the period of greater disease severity. The plants with high foliage index hence show large number of leaves, including new ones. Thereb, new leaves and leaves with absence of disease symptoms can overlap and hide the leaves with symptoms. Therefore, the sensor may decrease its precision and accuracy due to spectral mixing between leaves with and without symptoms of disease. Based on the reduction of the foliage (June to December), the number of leaves decreases similarly as the spectral mixture between the leaves with and without symptoms

of disease. allowing greater precision and accuracy of vegetation indices in the identification of disease severity.

**Table 4** Pearson correlation coefficients between the variables severity (%) of the bacterial blight (*Pseudomonas syringae* pv. *garcae*) in coffee plantations (*Coffea arabica*) and vegetation indices. Santo Antônio do Amparo. MG. Brazil. January to December 2014.

Vegetation indices	Jan	Feb	Apr	May	June	July	Aug	Sept	Oct	Nov	Dec	Annual average
SAVI	ns	ns	ns	ns	0,48	0,41	0,39	0,36	0,32	0,38	0,28	0,37
TVI	ns	ns	ns	ns	0,52	0,47	0,46	0,42	0,33	0,39	0,32	0,42
MCARI <sub>II</sub>	ns	ns	ns	ns	0,52	0,51	0,47	0,44	0,34	0,39	0,32	0,43
MCARI <sub>2</sub>	ns	ns	ns	ns	0,46	0,43	0,38	0,35	0,31	0,37	0,28	0,37
MTVI <sub>1</sub>	ns	ns	ns	ns	0,50	0,37	0,40	0,37	0,32	0,36	0,32	0,38
MTVI <sub>2</sub>	ns	ns	ns	ns	0,48	0,33	0,38	0,36	0,31	0,38	0,30	0,36
GNDVI	ns	ns	ns	ns	0,38	0,48	0,36	0,33	0,25	0,39	ns	0,37
MSAVI	ns	ns	ns	ns	0,41	0,38	0,38	0,32	0,30	0,32	ns	0,35
NDVI	ns	ns	ns	ns	0,36	0,35	0,35	0,30	0,27	0,23	ns	0,31
NDWI	ns	ns	ns	ns	0,44	0,32	0,33	0,32	0,25	0,24	ns	0,32
RDVI	ns	ns	ns	ns	0,36	0,35	0,35	0,31	0,27	0,28	ns	0,32
SR	ns	ns	ns	ns	0,34	0,34	0,35	0,31	0,27	0,25	ns	0,31
SIP <sub>I</sub>	ns	ns	ns	ns	0,39	0,44	0,37	0,33	0,30	0,30	ns	0,36
MSR	ns	ns	ns	ns	0,35	0,34	0,35	0,28	0,27	0,28	ns	0,31
GARI	ns	ns	ns	ns	0,32	0,32	0,32	0,28	0,26	ns	ns	0,30

ns= not significant

The highest correlation coefficient values between disease incidence and vegetation indices when compared to correlation index values with disease severity (Tables 3 and 4) may be associated with the best conditions for identification of the disease by satellite images provided by the incidence analysis. The disease incidence analysis indicates the rate of plants with symptoms of the disease, while the severity shows the rate of leaves with symptoms. Therefore, due to the 30 m resolution of the Landsat 8 OLI/TIRS, the sensor has more difficulty to identify leaves with symptoms of disease than whole plants with symptoms.

The correlation between the coffee foliage variable and vegetation indices maintained the correlation pattern between disease incidence and severity with vegetation indices (Table 5).

**Table 5** Pearson correlation coefficients between the variables foliage (%) of the bacterial blight (*Pseudomonas syringae* pv. *garcae*) in coffee plantations (*Coffea arabica*) and vegetation indices. Santo Antônio do Amparo. MG. Brazil. January to December 2014.

Vegetation indices	Jan	Feb	Apr	May	June	July	Aug	Sept	Oct	Nov	Dec	Annual average
SAVI	ns	ns	ns	ns	0,56	0,41	0,53	0,4	0,39	0,38	0,28	0,42
TVI	ns	ns	ns	ns	0,58	0,44	0,53	0,41	0,39	0,39	0,27	0,43
MCARI1	ns	ns	ns	ns	0,58	0,51	0,55	0,45	0,4	0,39	0,3	0,45
MCARI2	ns	ns	ns	ns	0,54	0,4	0,54	0,38	0,35	0,38	0,26	0,41
MTVII	ns	ns	ns	ns	0,56	0,43	0,53	0,39	0,36	0,38	0,28	0,42
MTVI2	ns	ns	ns	ns	0,54	0,41	0,54	0,39	0,4	0,37	0,28	0,42
GNDVI	ns	ns	ns	ns	0,54	0,32	0,53	0,35	0,28	0,31	0,27	0,37
MSAVI	ns	ns	ns	ns	0,53	0,36	0,54	0,33	0,31	0,33	0,22	0,37
NDVI	ns	ns	ns	ns	0,51	0,31	0,55	0,32	0,31	0,3	0,27	0,37
NDWI	ns	ns	ns	ns	0,55	0,4	0,52	0,39	0,27	0,27	0,26	0,38
RDVI	ns	ns	ns	ns	0,51	0,3	0,55	0,34	0,29	0,3	ns	0,38
SR	ns	ns	ns	ns	0,5	0,3	0,55	0,34	0,28	0,27	ns	0,37
SICI	ns	ns	ns	ns	0,54	0,33	0,54	0,36	0,31	0,3	0,31	0,38
MSR	ns	ns	ns	ns	0,51	0,3	0,54	0,37	0,29	0,27	ns	0,38
GARI	ns	ns	ns	ns	0,49	0,28	0,53	0,26	0,26	ns	ns	0,36

ns= not significant

Correlation coefficient values were positive for all vegetation indices. However, similarly as severity, there was no significant correlation from January to May. The MCARI1 vegetation indice showed again the highest correlation coefficient values in the months of June ( $r= 0,58$ ), July ( $r= 0,51$ ) and August ( $r= 0,55$ ) whereas the vegetation indice GARI showed the lowest values in November and December (not significant correlations).

According to the established pattern of vegetation indices correlations with the variables incidence and severity of the bacterial blight of coffee and

coffee foliage, it was possible to suggest that MCARI1 is efficient to identify the coffee plantation with symptoms of bacterial blight of coffee. On the other hand, the GARI showed lower efficiency among the studied indices. Moreover, the most appropriate period to identify the bacterial blight of coffee as a function of the spectral reflectance of the coffee crop is from June to August, during the dry season.

Although Moreira et al. (2004) did not study the relationship between disease and spectral reflectance of coffee, these authors showed that the best period to monitor coffee is the dry season, from June to September, since the coffee reflectance undergo less spectral mixing of other targets at this time of year.

The positive correlation between the vegetation indices and the intensity of the bacterial blight of coffee can be explained by the higher yield of plants with lower incidence and severity of the disease (Fig. 3). They were more productive, showing more fruits and lower foliage since the most productive plants are weakened due to the drainage of nutrients from leaves to fruits in years of high productivity. Thus, there are physiological disturbances in the plant, culminating in leaf fall, reduction of photosynthesis and low productivity in the subsequent year (Silva et al. 2010). Therefore, vegetation indices values were higher in the region with higher incidence and severity of the disease and lower productivity, as a function of a higher amount of leaves that resulted in the increase of near-infrared reflectance.

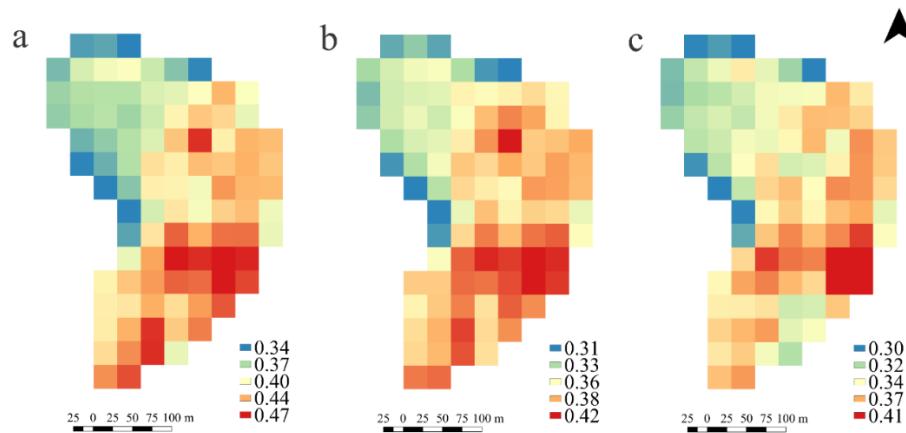
Bispo (2013) also reported that both the vegetation indices and the near-infrared band were inversely proportional to coffee yield (*Coffea arabica*). These authors verified that the near-infrared better correlated ( $r = -0.80$ ) to enhanced vegetation index (EVI) and normalized difference vegetation index (NDVI), with ( $r = -0.68$ ) and ( $r = -0.40$ ), respectively.

Another factor that may contribute to the correlation between the vegetation indices and the bacterial blight of coffee is the alteration in the internal

structures of leaves, caused by bacterial colonization of leaf tissues. According to Rodrigues et al (2017), *Pseudomonas syringae* pv. *garcae* can cause cell necrosis in the palisade parenchyma, hypertrophy and hyperplasia of mesophyll cells and partial destruction of chloroplasts. In this context, the reflectance in the near-infrared spectral region may have been higher and hence the vegetation indices values increased, since the electromagnetic radiation behavior in the near-infrared region is dominated by the optical properties of the leaf, which depend on the internal cellular structures (Slaton 2001; Moreira et al. 2004). The increase of the reflectance in the near-infrared spectral region due to the alteration of the internal structure of leaves was observed by Motomiya et al. (2012). When mapping cotton crops, these authors reported higher values of NDVI for crops attacked by bedbugs. According to these authors, bedbug attack directly affects the roots, responsible for absorbing both water and nutrients, thus modifying the anatomical structure of the leaf mesophyll, causing the greater reflectance in the attacked crop than in the healthy one.

The positive correlation of vegetation indices with the bacterial blight of coffee may also be associated to the vegetation in plants with higher incidence and severity of the disease. When colonizing both the plagiotropic and orthotropic branches of the coffee plantation, there may be death of apical meristem, which led the plants to emit new branches, giving rise to oversprouting symptoms (Rodrigues et al. 2013). Therefore, the plants infected by the disease may show higher phytomass and hence higher values of vegetation indices.

The spatial distribution of the MCARI1 vegetation indice for the months of higher correlation coefficients with the disease incidence and severity variables was similar with the spatial distribution of the disease (Fig. 10).



**Fig. 10** Spatial distribution maps of the MCARI1 vegetation indice from June to August 2014. June/14 (a). July/14 (b). August/14 (c) in coffee plantation (*Coffea arabica*) containing plants with symptoms of bacterial blight (*Pseudomonas syringae* pv. *garcae*). Santo Antônio do Amparo. MG. Brazil. January to December 2014.

In the southeast region of the crop, higher values of the MCARI1 indice (0.40 on average) were identified, as well as the highest values for incidence (82% on average) and severity (1.60% on average) of the disease. While in the northwest region, the lowest values for MCARI1 (0.31 on average), incidence (38% on average) and severity (0.42% on average). The similar spatial distribution between vegetation indices and plant disease was also reported by Martins and Galo (2014). The thematic maps resulting from the combination of the NDVI and the red edge band showed coincidence of 84% with the distribution of nematodes in the field and 70% with the distribution of *Migdolus frysianus*. However, in the present study, the indice that showed similar spatial distribution with the disease was MCARI1.

### Brightness temperature

The spatial distribution of the brightness temperature in the crop throughout the year allowed identifying regions of higher and smaller occurrence of the bacterial blight of coffee (Fig. 11).

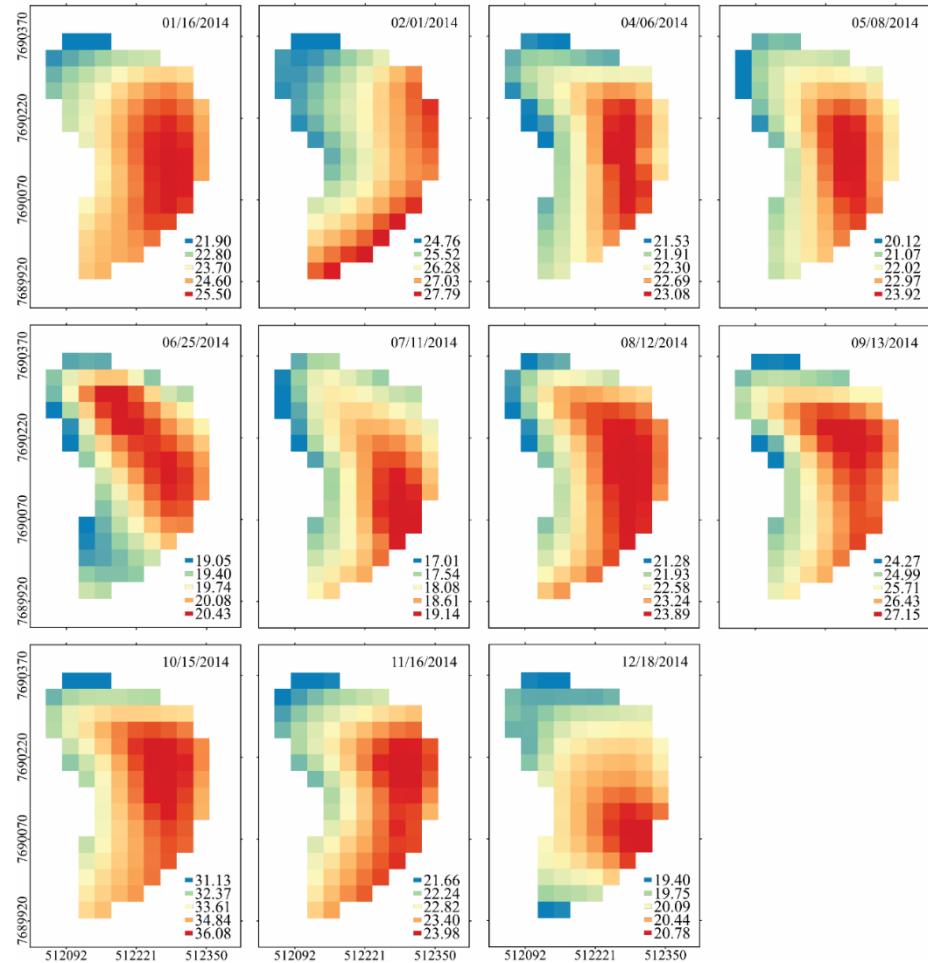
The southeast region of the crop, which has the highest occurrence of the disease, showed an annual average temperature of 23.92 °C, while the northwest region, with the lowest occurrence of the disease, showed 23.19 °C. The highest temperature in the southeast region may be associated with changes in transpiration and water content of coffee leaves caused by the higher disease intensity in this region, since leaf temperature increases inasmuch as the rate of transpiration is decreased (Jones and Schofield 2008; Oerke and Steiner 2010).

The change in leaf temperature as a function of pathogen action was also observed by Stoll et al. (2008). These authors monitored, under greenhouse conditions, the temperature of grape (*Vitis vinifera* L. cv. Riesling) leaves infected and non-infected by the pathogen (*Plasmopara viticola*). The analysis of the thermal images showed that the leaves infected by the pathogen showed temperature higher when compared to the non-infected leaves.

Despite the difference of 0.73 °C between the brightness temperature of the southeast region and the northwest region, both temperatures may have favored the development of the bacterial blight of coffee. According to Perez et al. (2017), the temperature of 23 °C combined with the unbalanced nutrition of plants is considered as ideal for the incidence of the bacterial blight of coffee

It is worth noting that the brightness temperature showed higher values in the southeast region of the crop, while the meteorological stations CR10X (northernmost) and CR1000 (southernmost) in the northwest region. Furthermore, the aspect of the terrain (Fig. 7) indicated that the northwest region of the crop is more exposed to solar radiation throughout the year, thus suggesting a higher

temperature in this region. However, this fact can be explained since the brightness temperature is a direct measure of the temperature of plants, whereas the weather stations and the aspect are indirect measures of plants. In this context, the brightness temperature might be more efficient to indicate the temperature more favorable to the occurrence of the bacterial blight of coffee.



**Fig. 11** Spatial distribution maps of the brightness temperature at coffee plantations (*Coffea arabica*) located in the municipality of Santo Antônio do Amparo. MG. Brazil. from January to December 2014.

## **Conclusions**

It was possible to monitor the spatial and temporal progress of crops affected by the bacterial blight using the Landsat 8 OLI/TIRS multispectral orbital images.

The vegetation indices proposed in the present study allowed identifying regions in the crop with higher intensities of the bacterial blight of coffee.

The brightness temperature aided in the process of mapping areas with the ideal temperature conditions for the occurrence of the coffee blight spot.

## **Acknowledgements**

To the Neumman Kaffee Gruppe (NKG) for allowing implementing the experiments in their crops and providing the management logistics of these areas. To the technical support team and the Foundation for Supporting Research of the State of Minas Gerais (FAPEMIG) for funding the study.

## **References**

- Amaral, J. D., Teixeira, C., & Pinheiro, E. D. (1956). A bactéria causadora da mancha aureolada do cafeeiro. *Arquivo do Instituto Biológico de São Paulo (Brasil)*, 23, 151.
- Ahamed, T., Tian, L., Zhang, Y., & Ting, K. C. (2011). A review of remote sensing methods for biomass feedstock production. *Biomass and Bioenergy*, 35(7), 2455-2469. doi: 10.1016/j.biombioe.2011.02.028
- Ashourloo, D., Mobasher, M. R., & Huete, A. (2014). Evaluating the effect of different wheat rust disease symptoms on vegetation indices using hyperspectral measurements. *Remote Sensing*, 6(6), 5107-5123. doi: 10.3390/rs6065107

- Barbedo, J. G. A. (2013). Digital image processing techniques for detecting, quantifying and classifying plant diseases. *SpringerPlus*, 2(1), 660. doi: 10.1186/2193-1801-2-660
- Belan, L. L., Pozza, E. A., Freitas, M. L. D. O., Souza, R. M., Jesus Junior, W. C., & Oliveira, J. M. (2014). Diagrammatic scale for assessment of bacterial blight in coffee leaves. *Journal of Phytopathology*, 162(11-12), 801-810. doi: 10.1111/jph.12272
- Belan, L. L., Pozza, E. A., Freitas, M. L. O., Raimundi, M. K., Souza, R. M., & Machado, J. C. (2016). Occurrence of 'Pseudomonas syringae' pv. 'garcae' in coffee seeds. *Australian Journal of Crop Science*, 10(7), 1015-1021. doi: 10.21475/ajcs.2016.10.07.p7693
- Birth, G. S., & McVey, G. R. (1968). Measuring the color of growing turf with a reflectance spectrophotometer. *Agronomy Journal*, 60(6), 640-643. doi: 10.2134/agronj1968.00021962006000060016x
- Bispo, R. C. (2013). *Utilização de dados do sensor MODIS no monitoramento e mapeamento da cultura do café*. Campinas, Brasil: Universidade Estadual de Campinas.
- Boechat, L. T., Pinto, F. A. C., Júnior, T. J. P., Queiroz, D. M., & Teixeira, H. (2014). Detecção do mofo-branco no feijoeiro, utilizando características espetrais. *Revista Ceres*, 61(6), 907-915
- Boldini, J. M. (2001). *Epidemiologia da ferrugem e da cercosporiose em cafeeiro irrigado e fertirrigado*. Lavras, Brasil: Universidade Federal de Lavras.
- Broge, N. H., & Leblanc, E. (2001). Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment*, 76(2), 156-172. doi: 10.1016/S0034-4257(00)00197-8
- Chappelle, E. W., Kim, M. S., & McMurtrey, J. E. (1992). Ratio analysis of reflectance spectra (RARS): An algorithm for the remote estimation of the concentrations of chlorophyll a, chlorophyll b., and carotenoids in soybean leaves. *Remote Sensing of Environment*, 39(3), 239-247. doi: 10.1016/0034-4257(92)90089-3

- Chemura, A., Mutanga, O., Sibanda, M., & Chidoko, P. (2017). Machine learning prediction of coffee rust severity on leaves using spectroradiometer data. *Tropical Plant Pathology*, 1-11. doi: 10.1007/s40858-017-0187-8
- Chemura, A., Mutanga, O., & Dube, T. (2016). Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. *Precision Agriculture*, 18(5), 859-881. doi: 10.1007/s11119-016-9495-0
- Chen, J. M. (1996). Evaluation of vegetation indices and a modified simple ratio for boreal applications. *Canadian Journal of Remote Sensing*, 22(3), 229-242. doi: 10.1080/07038992.1996.10855178
- Chen, Z. (2002). *Morphocultural and pathogenic comparisons between Colletotrichum kahawae and Colletotrichum gloeosporioides isolated from coffee berries*. Lisboa, Portugal: Universidade Técnica de Lisboa, Instituto Superior de Agronomia.
- De Biasi, M. (1970). Carta de declividade de vertentes: confecção e utilização. *Geomorfologia*, 21, 8-13.
- Gao, B. C. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257-266. doi: 10.1016/S0034-4257(96)00067-3
- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3), 289-298. doi: 10.1016/S0034-4257(96)00072-7
- Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J., & Strachan, I. B. (2004). 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*, 90(3), 337-352. doi: 10.1016/j.rse.2003.12.013
- Honorato Júnior, J., Zambolim, L., Aucique-Pérez, C. E., Resende, R. S., & Rodrigues, F. A. (2015). Photosynthetic and antioxidative alterations in coffee leaves caused by epoxiconazole and pyraclostrobin sprays and *Hemileia vastatrix* infection. *Pesticide Biochemistry and Physiology*, 123, 31-39. doi: 10.1016/j.pestbp.2015.01.016

- Huang, W., Guan, Q., Luo, J., Zhang, J., Zhao, J., Liang, D., et al. (2014). New optimized spectral indices for identifying and monitoring winter wheat diseases. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), 2516-2524. doi: 10.1109/JSTARS.2013.2294961
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295-309. doi: 10.1016/0034-4257(88)90106-X
- Ito, D. S., Sera, T., Sera, G. H., Del Grossi, L., & Kanayama, F. S. (2008). Resistance to bacterial blight in arabica coffee cultivars. *Crop Breeding and Applied Biotechnology*, 8(2), 99-103. doi: 10.12702/1984-7033.v08n02a01
- Ithiru, J. M., Gichuru, E. K., Gitonga, P. N., Cheserek, J. J., & Gichimu, B. M. (2013). Methods for early evaluation for resistance to bacterial blight of coffee. *African Journal of Agricultural Research*, 8(21), 2450-2454. doi: 10.5897/AJAR2013.6717
- Jones, H. G., & Schofield, P. (2008). Thermal and other remote sensing of plant stress. *General and Applied Plant Physiology*, 34(1-2), 19-32.
- Korobko A., & Wondimagegne E. (1997) Bacterial blight of coffee (*Pseudomonas syringae* pv. *garcae*) in Ethiopia. In: Rudolph, K., Burr, T. J., Mansfield, J. W., Stead, D., Vivian, A., von Kietzell J. (Eds.), *Pseudomonas syringae pathovars and related pathogens* (pp. 538-541). Dordrecht: Springer.
- Lamichhane, J. R., Fabi, A., Ridolfi, R., & Varvaro, L. (2013). Epidemiological study of hazelnut bacterial blight in central Italy by using laboratory analysis and geostatistics. *PLoS one*, 8(2), e56298. doi: 10.1371/journal.pone.0056298
- Martins, G. D., & Galo, M. D. L. B. T. (2014). Detecção de áreas infestadas por nematóides e *Migdolus fryanus* em cultura canavieira a partir de imagens multiespectrais Rapideye. *Revista Brasileira de Cartografia*, 1(66/2), 285-301.
- Mahlein, A. K., Rumpf, T., Welke, P., Dehne, H. W., Plümer, L., Steiner, U., & Oerke, E. C. (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128, 21-30. doi: 10.1016/j.rse.2012.09.019

- Mahlein, A. K., Oerke, E. C., Steiner, U., & Dehne, H. W. (2012). Recent advances in sensing plant diseases for precision crop protection. *European Journal of Plant Pathology*, 133(1), 197-209. doi: 10.1007/s10658-011-9878-z
- Moreira, M. A., Adami, M., & Rudorff, B. F. T. (2004). Análise espectral e temporal da cultura do café em imagens Landsat. *Pesquisa Agropecuária Brasileira*, 39(3), 223-231. doi: 10.1590/S0100-204X2004000300004
- Moscetti, R., Haff, R. P., Stella, E., Contini, M., Monarca, D., Cecchini, M., & Massantini, R. (2015). Feasibility of NIR spectroscopy to detect olive fruit infested by *Bactrocera oleae*. *Postharvest Biology and Technology*, 99, 58-62. doi: 10.1016/j.postharvbio.2014.07.015
- Motomiya, A. V. A., Molin, J. P., Motomiya, W. R., & Baio, F. H. R. (2012). Mapeamento do índice de vegetação da diferença normalizada em lavoura de algodão. *Pesquisa Agropecuária Tropical*, 42(1), 112-118. doi: 10.1590/S1983-40632012000100016
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems engineering*, 114(4), 358-371. doi: 10.1016/j.biosystemseng.2012.08.009
- Oerke, E. C., & Steiner, U. (2010). Potential of digital thermography/thermography for disease control. In: Oerke, E. C., Gerhards, R., Menz, G., Sikora, R. (Eds.), *Precision crop protection - the Challenge and use of heterogeneity* (pp. 167-182). Netherlands: Springer.
- Oumar, Z., & Mutanga, O. (2014). Integrating environmental variables and WorldView-2 image data to improve the prediction and mapping of *Thaumastocoris peregrinus* (bronze bug) damage in plantation forests. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 39-46. doi: 10.1016/j.isprsjprs.2013.10.010
- Park, Y. L., Perring, T. M., Krell, R. K., Hashim-buckey, J. M., & Hill, B. L. (2011). Spatial distribution of Pierce's disease related to incidence, vineyard characteristics, and surrounding land uses. *American Journal of Enology and Viticulture*, <http://www.ajevonline.org/content/62/2/229>
- Penuelas, J., Baret, F., & Filella, I. (1995). Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. *Photosynthetica*, 31(2), 221-230.

- Pérez, C. D. P., Pozza, E. A., Pozza, A. A. A., Freitas, A. S., & Silva, M. G. D. (2017). Nitrogênio e potássio na intensidade da mancha aureolada do cafeeiro em solução nutritiva. *Coffee Science*, 12(1), 60-68.
- Pinter Jr, P. J., Hatfield, J. L., Schepers, J. S., Barnes, E. M., Moran, M. S., Daughtry, C. S., et al. (2003). Remote sensing for crop management. *Photogrammetric Engineering & Remote Sensing*, 69(6), 647-664.
- Pozza, E. A., Carvalho, V. L., & Chalfoun, S. M. (2010). Sintomas de injurias causadas por doenças do cafeeiro. In: Guimarães, R. J., Mendes, A. N. G., Baliza, D. P. (Eds.), *Semiologia do Cafeeiro* (pp. 67-106). Brasil: Editora UFLA.
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119-126. doi: 10.1016/0034-4257(94)90134-1
- Qin, Z., & Zhang, M. (2005). Detection of rice sheath blight for in-season disease management using multispectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 7(2), 115-128. doi: 10.1016/j.jag.2005.03.004
- Rodrigues, L. M., Almeida, I. M., Patrício, F. R., Beriam, L. O., Maciel, K. W., & Braghini, M. T. (2017). Aggressiveness of strains and inoculation methods for resistance assessment to bacterial halo blight on coffee seedlings. *Journal of Phytopathology*, 165(2), 105-114. doi: 10.1111/jph.12543
- Rodrigues, L. M. R., Queiroz-Voltan, R. B., & Guerreiro Filho, O. (2015). Anatomical changes on coffee leaves infected by *Pseudomonas syringae* pv. *garcae*. *Summa Phytopathologica*, 41(4), 256-261. doi: 10.1590/0100-5405/2049
- Rodrigues, L. M. R., Ameida, I. M. G., Patricio, F. R. A., Beriam, L. O. S., Maciel, K. W., Braghini, M. T., et al. (2013). *Mancha aureolada do cafeeiro causada por Pseudomonas syringae* pv. *garcae*. Brasil: Instituto Agronômico de Campinas.
- Ramos, A. H., & Shavdia, L. D. (1976). A dieback of coffee in Kenya. *Plant Disease Reporter*, 60(10), 831-835.
- Roumagnac, P., Pruvost, O., Chiroleu, F., & Hughes, G. (2004). Spatial and temporal analyses of bacterial blight of onion caused by *Xanthomonas*

- axonopodis* pv. *allii*. *Phytopathology*, 94(2), 138-146. doi: 10.1094/PHYTO.2004.94.2.138
- Roujean, J. L., & Breon, F. M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3), 375-384. doi: 10.1016/0034-4257(94)00114-3
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring vegetation systems in the Great Plains with ERTS. *Third ERTS Symposium*, 1, 309–317.
- Sankaran, S., Mishra, A., Ehsani, R., & Davis, C. (2010). A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture*, 72(1), 1-13. doi: 10.1016/j.compag.2010.02.007
- Sera, T. (2001). Coffee genetic breeding at IAPAR. *Crop Breeding and Applied Biotechnology*, 1(2), 179-190. doi: 10.13082/1984-7033.v01n02a08
- Silva, F. M. D., Alves, M. D. C., Souza, J. C. S., & Oliveira, M. S. D. (2010). Effects of manual harvesting on coffee (*Coffea arabica* L.) crop biannuality in Ijaci, Minas Gerais. *Ciência e Agrotecnologia*, 34(3), 625-632. doi: 10.1590/S1413-70542010000300014
- Slaton, M. R., Hunt, E. R., & Smith, W. K. (2001). Estimating near-infrared leaf reflectance from leaf structural characteristics. *American Journal of Botany*, 88(2), 278-284.
- USDA. (2017). *Annual Report Coffee Annual Brazil*. <http://usda.mannlib.cornell.edu/usda/fas/tropprod//2010s/2016/tropprod-12-16-2016.pdf> Acessed 2 November 2017.
- USGS. (2017). *Landsat 8 (L8) Level 1 (L1) Data format control book (DFCB)*. <https://landsat.usgs.gov/sites/default/files/documents/LSDS-809-Landsat8-Level1DFCB.pdf> Acessed 22 March 2017.
- Stoll, M., Schultz, H. R., & Berkelmann-Loehnertz, B. (2008). Exploring the sensitivity of thermal imaging for *Plasmopara viticola* pathogen detection in grapevines under different water status. *Functional Plant Biology*, 35(4), 281-288. doi: 10.1071/FP07204

Zoccoli, D. M., Takatsu, A., & Hidemi Uesugi, C. (2011). Ocorrência de mancha aureolada em cafeeiros na Região do Triângulo Mineiro e Alto Paranaíba. *Bragantia*, 70(4), 843-849.

Zhang, M., Qin, Z., Liu, X., & Ustin, S. L. (2003). Detection of stress in tomatoes induced by late blight disease in California, USA, using hyperspectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 4(4), 295-310. doi: 10.1016/S0303-2434(03)00008-4

**ARTIGO 2 - SENSORIAMENTO REMOTO MULTIESPECTRAL NA  
IDENTIFICAÇÃO E MAPEAMENTO DAS VARIÁVEIS BIÓTICAS E  
ABIÓTICAS DO CAFÉ**

<sup>1</sup>Diego Bedin Marin, <sup>1</sup>Marcelo de Carvalho Alves, <sup>2</sup>Edson Ampélio Pozza

<sup>1</sup>Departamento de Engenharia e Fitopatologia, Universidade Federal de Lavras,  
Caixa postal 3037, CEP 37200-000, Lavras, MG, Brazil.

<sup>2</sup>Departamento de Fitopatologia, Universidade Federal de Lavras, Caixa postal  
3037, CEP 37200-000, Lavras, MG, Brazil.

Artigo preparado de acordo com as normas do periódico “**Revista Ceres**”

(VERSÃO PRELIMINAR)

## RESUMO

Nos últimos anos os fatores bióticos e abióticos estão afetando cada vez mais o setor cafeeiro, resultando em perdas da produção e aumento dos impactos ambientais pela aplicação, em excesso, de fertilizantes e produtos fitossanitários. Diante disso, o sensoriamento remoto multiespectral, apresenta-se como uma metodologia confiável e viável para auxiliar o produtor na tomada de decisão para melhores práticas de manejo, garantindo uma produção agrícola mais eficiente e sustentável. Face ao exposto, este estudo teve como objetivo identificar e mapear o estresse em lavoura cafeeira (*Coffea arabica* L.) causado por variáveis bióticas e abióticas por meio de índices de vegetação derivados de imagens multiespectrais Landsat 5/TM. Na lavoura de estudo foi demarcada uma malha amostral composta por 67 pontos, sendo cada ponto amostral constituído por 5 plantas. As análises de incidência de cercosporiose e infestação do bicho-mineiro nas folhas, pH, matéria orgânica e textura do solo e teores foliares de macro e micronutrientes foram realizadas em cada um dos pontos amostrais e correlacionadas com 16 índices de vegetação obtidos a partir de imagens multiespectrais Landsat 5/TM referentes à época das análises. Os índices de vegetação apresentaram distribuição espacial semelhante à distribuição espacial das variáveis agronômicas na lavoura. Houve correlação positiva dos índices com a infestação do bicho-mineiro, teor de silte e argila no solo e concentração de Mg, Cu, B e Mn nas folhas, e negativas com a incidência de cercosporiose e pH e teor de areia no solo. Com base nestes resultados, foi possível mapear e identificar as alterações na reflectância espectral dos cafeeiros, causadas por estas variáveis agronômicas.

**Palavras-chave:** Lansat 5/TM; agricultura de precisão; variáveis agronômicas; *Coffea arabica* L.

## INTRODUÇÃO

O café brasileiro é uma *commodities* de grande impacto no comércio global. O Brasil é o maior produtor e exportador mundial de café, com 36% da produção mundial, equivalente a 56,1 milhões de sacas de 60 kg beneficiadas na safra de 2016/17 (USDA, 2017). No entanto vários fatores podem contribuir para a redução dessa produtividade e, por isso, a cafeicultura necessita de uma estratégia de monitoramento robusta, confiável e de baixo custo para doenças, pragas, estresse hídrico, fertilidade do solo, condições nutricionais e outros estressores de culturas (Chemura et al., 2017).

Nos últimos anos, as metodologias de sensoriamento remoto têm sido amplamente utilizadas no monitoramento das culturas agrícolas e na tomada de decisão para melhores práticas de manejo. Na cultura do café, o uso de dados de sensoriamento remoto provou ser muito promissor devido à dificuldade de se obter dados de campo em escala regional, especialmente para o mapeamento de campo, que necessitam de mão-de-obra qualificada, vistorias nas plantas em lavouras cultivadas em grandes áreas, demanda de tempo excessivo de atividade e, consequentemente, aumento do custo de produção (Bernardes et al., 2012).

O sensoriamento remoto espectral fornece a possibilidade de avaliação precoce, eficiente, objetiva e não destrutiva das respostas das plantas a diferentes fatores de estresse do meio ambiente (Li et al., 2010). As plantas reagem aos estresses biótico e abiótico através de mudanças biofísicas e bioquímicas, como redução de biomassa, do teor de clorofila e alterações nas estruturas internas das folhas, que podem ser facilmente detectadas através da diferença de energia refletida nas regiões espectrais do visível e infravermelho próximo (Barton, 2012; Mahajan et al., 2014). Além disso, essa diferença de reflectância entre as regiões espectrais do visível e do infravermelho próximo nas plantas sob estresse levaram

ao desenvolvimento de índices de vegetação (Mirik et al., 2006; Mirik et al., 2007; Hillnhütter et al., 2011).

Os índices de vegetação têm sido utilizados com o objetivo de aumentar a extração de informação espetrais ótimas da vegetação, e normalizar as medições feitas em condições ambientais variadas. Essas condições incluem diferenças entre espécies de plantas, sombreamento, cobertura do dossel, solo, condição atmosférica e geometria de visualização do sensor no espaço e tempo (Mirik et al., 2011; Ortiz et al., 2011; Subash et al., 2011).

Alguns trabalhos demonstraram que os índices de vegetação foram confiáveis para avaliar as condições de estresse das lavouras cafeeiras. Por exemplo, Chemura et al. (2016) relataram precisão de 82,5% na discriminação de diferentes níveis de infecção da ferrugem (*Hemileia vastatrix*) em lavoura de café (*Coffea arabica*) utilizando índices de vegetação obtidos a partir de medições feitas por espectro radiômetro. Já Santos et al. (2014), com o auxílio do índice de vegetação EVI-2 derivado do sensor MODIS, encontraram correlação de ( $R^2 = 0,81$ ) entre a umidade no perfil do solo (até 100 m de profundidade) e o vigor do cafeeiro (*Coffea arabica*). De forma semelhante, Bernardes et al. (2012), evidenciaram as variações provocadas pela bienalidade na produção de café em lavoura no sul do estado de Minas Gerais, no período entre 2002 e 2009, utilizando os índices de vegetação EVI e NDVI derivados de imagens MODIS. No entanto, esses estudos não avaliaram o potencial dos índices de vegetação obtidos a partir de imagens Landsat para avaliar as condições do cafeeiro. Além disso, os autores desses estudos concluíram que, apesar do potencial dos índices de vegetação na avaliação das condições do cafeeiro, estudos adicionais ainda são necessários para melhorar a acurácia e precisão da metodologia na avaliação das condições do cafeeiro.

Portanto, face ao exposto, este estudo teve como objetivo identificar e mapear o estresse em lavoura cafeeira (*Coffea arabica* L.) causado por variáveis

bióticas e abióticas por meio de índices de vegetação derivados de imagens multiespectrais Landsat 5/TM.

## MATERIAL E MÉTODOS

### *Área de estudo*

O estudo foi realizado na fazenda Cafua, situada no município de Ijaci, sul de Minas Gerais, com uma área total de 6,5 ha de lavoura de cafeiro (*Coffea arabica* L.) da cultivar Mundo Novo, com 10 anos de idade, espaçamento de 4m entre linhas e 1m entre plantas, totalizando 2500 plantas ha<sup>-1</sup> (Figura 1). As coordenadas geográficas são de 21º 10' 11" de latitude Sul e 44º 58' 37" de longitude Oeste de Greenwich, com altitude média de 934 metros e declividade de 0,84 % no sentido norte-sul e de 12 % no sentido leste-oeste. A malha amostral foi composta por 67 pontos georreferenciados com distâncias de 25x25 m e 50x50 m entre si. Cada ponto amostral foi constituído por 5 plantas, sendo 4 plantas distribuídas em torno de uma planta central. O georreferenciamento dos pontos foi realizado com GPS TRIMBLE 4600 LS® e Estação Total Leica TC600®, com base em correção de cotas por coordenadas conhecidas no câmpus da Universidade Federal de Lavras.

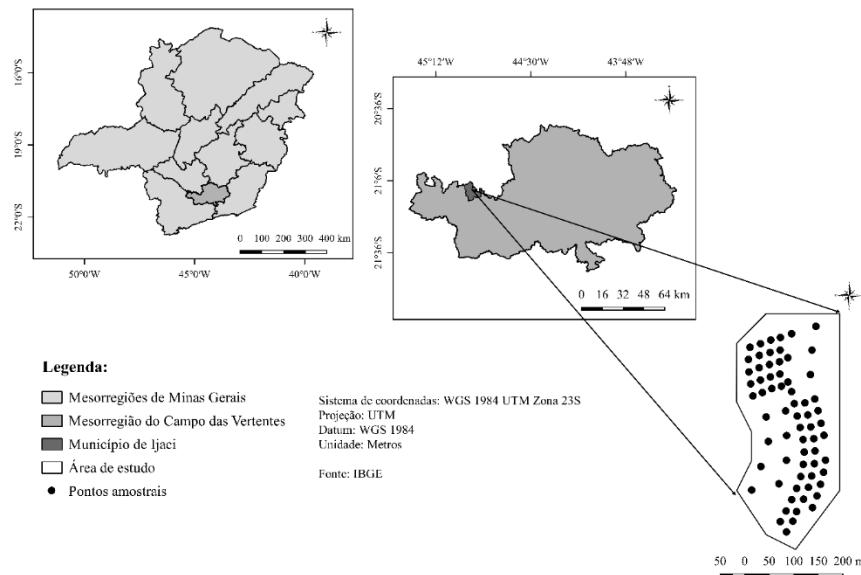


Figura 1 - Localização geográfica da lavoura (*Coffea arabica* L.) de estudo e malha amostral com 67 pontos distantes 25x25 m e 50x50 m entre si. Cada ponto georreferenciado no mapa foi constituído por cinco cafeeiros na linha de plantio. Ijaci – MG, Brasil.

#### Avaliações das variáveis bióticas e abióticas na lavoura

Avaliações da incidência da cercosporiose *Cercospora coffeicola* (Berkeley & Cooke) nas folhas (%) e infestação do bicho-mineiro (*Leucoptera coffeella*) (Guérin-Mèneville, 1842) (Lepidoptera:Lyonetiidae) também nas folhas (%), foram realizadas observando os sinais da doença em 100 folhas coletadas em cada ponto georreferenciado. Cada ponto amostrado consistiu em cinco plantas. As amostras foram coletadas aleatoriamente de cada lado da linha de plantação, correspondendo aos pontos cardeais oeste e leste, no terço médio das plantas, com dez folhas amostradas por planta em cada lado da linha de plantação, a partir do terceiro e quarto par de folhas, contados a partir do final do ramo plagiotrópico, totalizando 6700 folhas, de acordo com as recomendações de

Huerta (1963) e Boldini (2001). As folhas foram destacadas e analisadas no Laboratório de Epidemiologia e Gestão da Universidade Federal de Lavras.

O teor de macronutrientes K e Mg ( $\text{gkg}^{-1}$ ) e de micronutrientes Cu, B, Fe, Mn (ppm) nas folhas foi avaliado de acordo com metodologia proposta por Malavolta et al. (1997). Foram amostradas 5 folhas de cada lado da rua, na direção leste e oeste, em três plantas por ponto, totalizando 1005 folhas. Logo após a coleta, as amostras foram submetidas à limpeza com água corrente e enxaguadas em água deionizada para remover contaminações na superfície. Em seguida foi realizada a secagem das folhas a  $60^{\circ}\text{C}$  em estufa, por 72 horas. A matéria seca das folhas foi moída e armazenada em frascos de vidro para proceder as determinações analíticas.

As análises de pH, matéria orgânica e textura do solo foram realizadas na camada de 0-20 cm, de acordo com metodologia de Cantarutti et al. (1999), na projeção da copa das plantas, em cada ponto amostral.

As avaliações da incidência da cercosporiose nas folhas, infestação do bicho-mineiro nas folhas e teor de macro e micronutrientes foram realizadas em 29/05/2006, e as análises de pH, matéria orgânica e textura do solo em 04/02/2006.

### *Índices de vegetação*

Os índices de vegetação (Tabela 1) foram calculados a partir de imagens multiespectrais Landsat 5 TM (*Thematic Mapper*) *Collection 1 Level 2*, nas datas de 26/01/2006 e 18/05/2006. Essas imagens foram adquiridas da United States Geological Survey (USGS) em valores de reflectância nas bandas espectrais do azul (0,45 a 0,52  $\mu\text{m}$ ), verde (0,52 a 0,60  $\mu\text{m}$ ), vermelho (0,63 a 0,69  $\mu\text{m}$ ), infravermelho próximo (0,76 a 0,90  $\mu\text{m}$ ), infravermelho médio 1 (1,55 a 1,75  $\mu\text{m}$ ) e infravermelho médio 2 (2,08 a 2,35  $\mu\text{m}$ ) e com correção atmosférica Second

Simulation of Satellite Signal in the Solar Spectrum (6S). Dessa forma, não foi realizado pré-processamento das imagens. A escolha dos dezesseis índices de vegetação foi baseada na capacidade desses índices em discriminar diferentes características e condições de estresse da vegetação a partir de dados de sensoriamento remoto (Eitel et al., 2006).

#### *Análise de correlação*

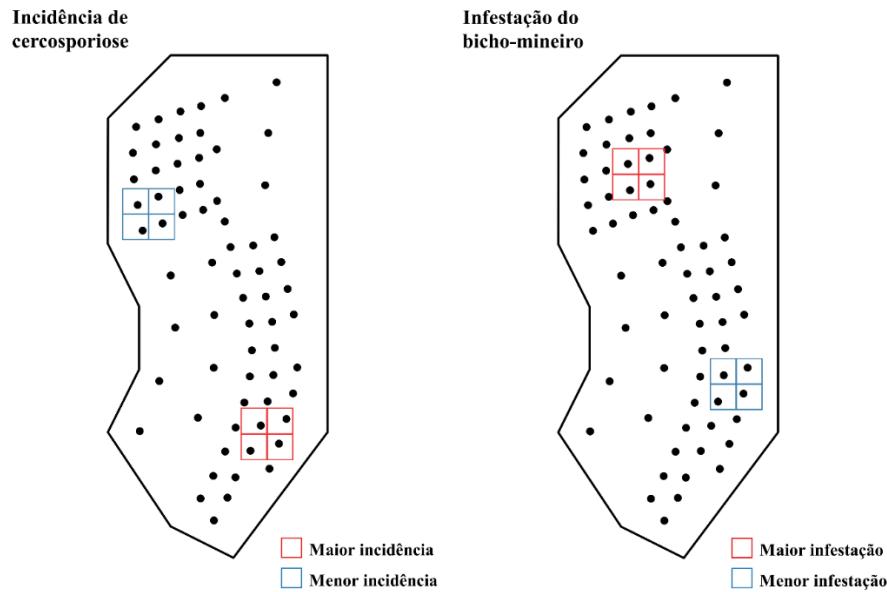
Os dados de análise da incidência da cercosporiose nas folhas, infestação do bicho-mineiro nas folhas, teor de macro e micronutrientes nas folhas, pH, matéria orgânica e textura do solo e os valores dos índices de vegetação calculados para cada pixel referente aos 67 pontos amostrais foram submetidos à análise de correlação de Pearson ( $p=0,01\%$ ).

#### *Assinatura espectral*

A assinatura espectral das variáveis incidência de cercosporiose e infestação do bicho-mineiro nas folhas foi calculada a partir da reflectância das bandas espectrais do azul, verde, vermelho, infravermelho próximo e infravermelho médio em uma área na região sudeste e outra no noroeste, regiões da lavoura com maior e menor incidência de cercosporiose e infestação do bicho-mineiro nas folhas. Para isso, foi estabelecida área de 2x2 pixels na região sudeste e outra no noroeste da lavoura (Figura 2).

**Tabela 1:** Índices de vegetação obtidos a partir da refletância das bandas multiespectrais das imagens Landsat 5/TM

Vegetation indices	Formula	Source
SICI	$\frac{\rho_{\text{nir}} - \rho_{\text{blue}}}{\rho_{\text{nir}} + \rho_{\text{red}}}$	Peñuelas et al. (1995)
GARI	$\frac{\rho_{\text{nir}} - [\rho_{\text{green}} - 1.7(\rho_{\text{blue}} - \rho_{\text{red}})]}{[\rho_{\text{nir}} + (\rho_{\text{green}} - 1.7(\rho_{\text{blue}} - \rho_{\text{red}})]}$	Gitelson et al. (1996)
OSAVI	$\frac{(1 + 0.16)(\rho_{\text{nir}} - \rho_{\text{red}})}{\rho_{\text{nir}} + \rho_{\text{red}} + 0.16}$	Rondeaux et al. (1996)
TVI	$0.5[120(\rho_{\text{nir}} - \rho_{\text{green}}) - 200(\rho_{\text{red}} - \rho_{\text{green}})]$	Broge e Leblanc (2001)
MCARI1	$1.2[2.5(\rho_{\text{nir}} - \rho_{\text{green}}) - 1.3(\rho_{\text{nir}} - \rho_{\text{green}})]$	Haboudane et al. (2004)
MCARI2	$\frac{1.2[2.5(\rho_{\text{nir}} - \rho_{\text{red}}) - 1.3(\rho_{\text{nir}} - \rho_{\text{green}})]}{\sqrt{2(\rho_{\text{nir}} + 1)^2 - 0.5} - 6(\rho_{\text{nir}} - 5\sqrt{\rho_{\text{red}}})}$	Haboudane et al. (2004)
MSAVI	$0.5[2\rho_{\text{nir}} + 1 - \sqrt{(2\rho_{\text{nir}} + 1)^2 - 8(\rho_{\text{nir}} - \rho_{\text{red}})}]$	Qi et al. (1994)
NDWI	$\frac{\rho_{\text{nir}} - \rho_{\text{swir1}}}{\rho_{\text{nir}} + \rho_{\text{swir1}}}$	Gao (1996)
NDVI	$\frac{\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}}}$	Rouse et al. (1973)
SAVI	$\frac{(1 + L)\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}} + L}$	Huete (1988)
GNDVI	$\frac{\rho_{\text{nir}} - \rho_{\text{green}}}{\rho_{\text{nir}} + \rho_{\text{green}}}$	Gitelson et al. (1996)
MTVI1	$1.2[1.2(\rho_{\text{nir}} - \rho_{\text{green}}) - 2.5(\rho_{\text{red}} - \rho_{\text{green}})]$	Haboudane et al. (2004)
MTVI2	$\frac{1.5[1(\rho_{\text{nir}} - \rho_{\text{green}}) - 2.5(\rho_{\text{red}} - \rho_{\text{green}})]}{\sqrt{[(2\rho_{\text{nir}} + 1)^2 - (6\rho_{\text{nir}} - 5\sqrt{\rho_{\text{red}}})] - 0.5}}$	Haboudane et al. (2004)
RDVI	$\sqrt{\frac{\rho_{\text{nir}} - \rho_{\text{red}}}{\rho_{\text{nir}} + \rho_{\text{red}}}}$	Roujean e Breon (1995)
MSR	$\frac{\left(\frac{\rho_{\text{nir}}}{\rho_{\text{red}}}\right) - 1}{\sqrt{\left(\frac{\rho_{\text{nir}}}{\rho_{\text{red}}}\right) + 1}}$	Chen (1996)
SR	$\frac{\rho_{\text{nir}}}{\rho_{\text{red}}}$	Birth e McVey (1968)



**Figura 2:** Localização geográfica das regiões de interesse utilizadas para o cálculo da assinatura espectral da incidencia da cercosporiose e infestação do bicho-mineiro na lavoura (*Coffea arabica*) de estudo. em Ijaci – MG, Brasil.

## RESULTADOS E DISCUSSÕES

### *Distribuição espacial das variáveis bióticas e abióticas e dos índices de vegetação*

Os mapas de distribuição espacial em 29/05/2006 da incidência de cercosporiose nas folhas e infestação do bicho-mineiro também nas folhas, apresentaram correspondência com os mapas de distribuição espacial dos índices de vegetação em 18/05/2006 (Figuras 3 e 4). Foi possível observar que a incidência de cercosporiose nas folhas apresentou correspondência inversa com

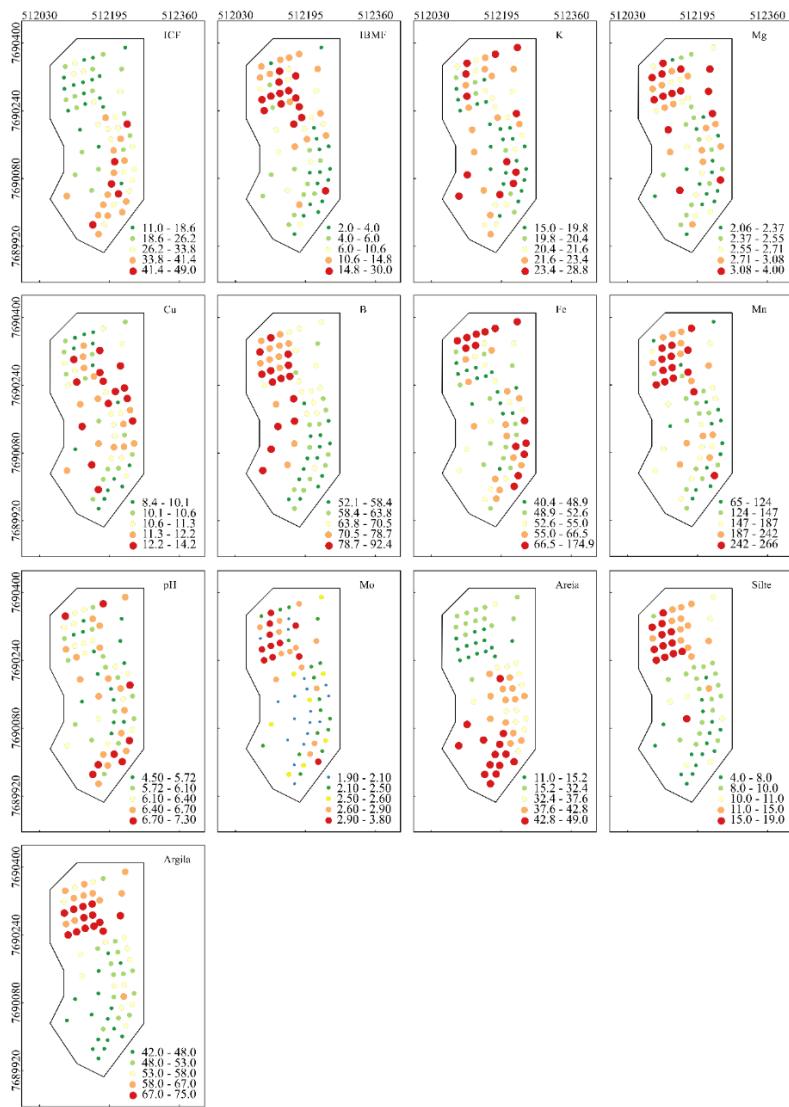
os índices de vegetação, enquanto a infestação do bicho-mineiro, correspondência direta.

A correspondência entre a distribuição espacial de doenças em plantas e os índices de vegetação também foi relatada por Martins & Galo (2014). Esses autores demonstraram que a distribuição espacial de nematoides e do besouro *Migdolus fryanus* em lavoura de cana-de-açúcar apresentaram correspondência com a distribuição espacial do NDVI, EVI e SAVI. De forma semelhante, Motomiya et al. (2012) relataram distribuição espacial com correspondência entre o NDVI e o ataque do percevejo castanho [*Scaptocoris castanea* (Hem.: Cydnidae)] em lavoura de algodão.

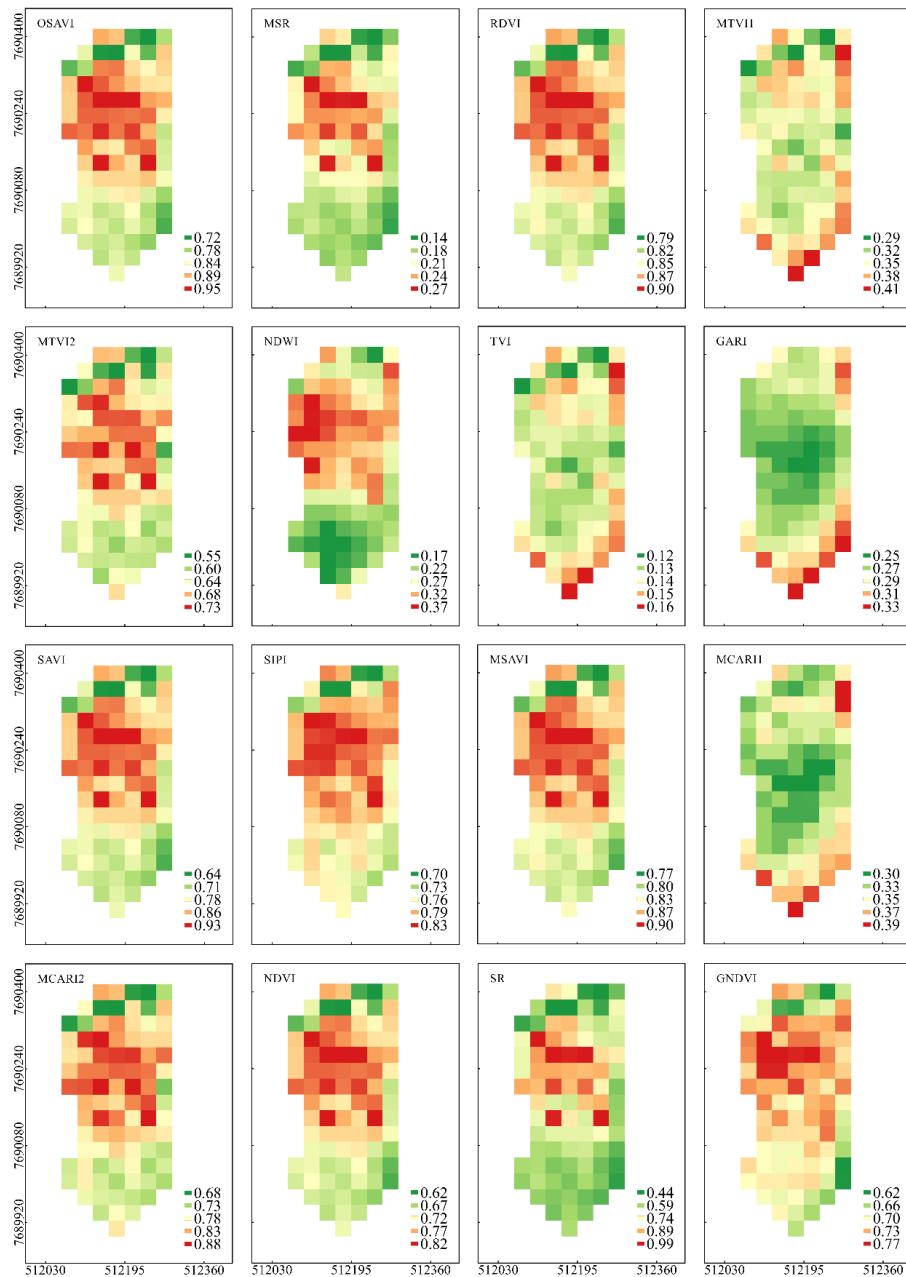
Para os mapas de distribuição espacial das características físicas, química e biológica do solo em 04/02/2006, houve correspondência direta da distribuição espacial dos índices de vegetação em 26/01/2006 com matéria orgânica, silte e argila, e correspondência inversa com pH e areia (Figuras 3 e 5).

Estudando a distribuição espacial das características do solo em um sistema integrado de colheita e pecuária, Bernardi et al. (2017) evidenciaram correspondência entre o NDVI e os parâmetros do solo pH, matéria orgânica, areia e argila. Já Zanzarini et al. (2013) relataram correspondência do NDVI com a distribuição de argila em um Latossolo vermelho-amarelo em área com produção de cana-de-açúcar. No entanto, ressalta-se que esses estudos não exploraram o potencial de outros índices de vegetação na relação com as características do solo, como é o caso do presente estudo.

Com relação aos mapas de distribuição espacial dos macros e micronutrientes nas folhas em 29/05/2006, houve correspondência direta da distribuição espacial dos índices de vegetação em 18/05/2006 com Mg, Cu, B e Mn, e correspondência indireta com K e Fe (Figuras 3 e 4).



**Figura 3:** Mapas de quantil da distribuição espacial em lavoura cafeeira (*Coffea arabica*) da incidência da cercosporiose nas folhas (ICF) (%), infestação do bicho-mineiro (IBMF) (%), potássio (K) ( $\text{mg} \cdot \text{dm}^{-3}$ ), magnésio (Mg) ( $\text{g} \cdot \text{kg}^{-1}$ ), cobre (Cu) ( $\text{mg} \cdot \text{dm}^{-3}$ ), boro (B) ( $\text{mg} \cdot \text{dm}^{-3}$ ), ferro (Fe) ( $\text{mg} \cdot \text{dm}^{-3}$ ), e manganês (Mn) ( $\text{mg} \cdot \text{dm}^{-3}$ ) em 29/05/2006 e do pH em água, matéria orgânica (Mo) ( $\text{dag} \cdot \text{kg}^{-1}$ ), areia ( $\text{dag} \cdot \text{kg}^{-1}$ ), silte ( $\text{dag} \cdot \text{kg}^{-1}$ ) e argila ( $\text{dag} \cdot \text{kg}^{-1}$ ) em 04/02/2006 . Ijaci – MG, Brasil.



**Figura 4:** Mapas de distribuição espacial dos índices de vegetação em lavoura cafeeira (*Coffea arabica*) derivado de imagem multiespectral Landsat 5/TM na data de 18/05/2006. Ijaci - Mg, Brasil.



**Figura 5:** Mapas de distribuição espacial dos índices de vegetação em lavoura cafeeira (*Coffea arabica*) derivados de imagem multiespectral Landsat 5/TM na data de 26/01/2006. Ijaci - Mg, Brasil.

***Análise de correlações entre as variáveis bióticas e abióticas e os índices de vegetação***

A variável incidência da cercosporiose nas folhas apresentou coeficientes de correlação negativo com os índices de vegetação. Em contrapartida, a variável infestação do bicho-mineiro nas folhas, coeficientes de correlação positivos (Tabela 2).

**Tabela 2:** Coeficientes de correlação de Pearson ( $p < 0,01$ ) entre as variáveis incidência da cercosporiose nas folhas e incidência do bicho-mineiro nas folhas em lavoura de cafeeiro (*Coffea arabica*) em 29/05/2006 e índices de vegetação em 18/05/2006. Ijaci - MG, Brasil

Índices de vegetação	Incidência da cercosporiose nas folhas	Infestação do bicho-mineiro nas folhas
OSAVI	-0,51	0,40
MSR	-0,51	0,38
RDVI	-0,51	0,35
MTVI1	-0,57	0,34
NDWI	-0,61	0,40
MTVI2	-0,47	0,31
TVI	-0,57	0,32
GARI	-0,47	0,35
SAVI	-0,51	0,36
SICI	-0,59	0,32
MSAVI	-0,51	0,35
MCARI1	-0,53	0,33
MCARI2	-0,47	0,32
NDVI	-0,51	0,36
SR	-0,51	0,38
GNDVI	-0,51	0,42

De maneira geral, observou-se que os valores de coeficientes de correlação entre os índices de vegetação e a incidência da cercosporiose nas folhas e infestação do bicho-mineiro nas folhas foram semelhantes para cada variável

independente. O índice NDWI apresentou o maior valor de coeficiente de correlação ( $r = -0,61$ ) com a incidência da cercosporiose, enquanto o GNDVI o maior ( $r = 0,42$ ) para a infestação do bicho-mineiro.

A correlação entre os índices de vegetação e a incidência da cercosporiose e infestação do bicho-mineiro nas folhas pode estar associado ao vigor vegetativo das plantas com presença desses organismos-praga. Segundo Ahamed et al. (2011), quanto maior o vigor vegetativo das plantas e, consequentemente, maior quantidade de folhas, menor a reflectância nas bandas do visível (azul, verde e vermelho) e maior na banda do infravermelho próximo. Além disso, a quantidade de folhas aumenta o teor de água na planta, provocando menor refletância na região do infravermelho médio (Moreira et al., 2004). Dessa forma, a correlação negativa entre os índices de vegetação e a incidência da cercosporiose nas folhas pode ser explicada em razão do menor vigor vegetativo das plantas com presença dessa doença. De acordo com Valencia (1970) e Zambolim et al. (1997) e, a cercosporiose provoca a produção em excesso de etileno nas folhas lesionadas sendo este o percursor de outro hormônio, o ácido abscísico, o qual provoca a queda precoce das folhas, diminuindo consideravelmente o vigor vegetativo. Portanto, os valores dos índices de vegetação tendem a diminuir em plantas com presença de cercosporiose, pois esses são calculados a partir da diferença de reflectância entre a banda do infravermelho próximo e as bandas do visível e infravermelho médio. Diferente dos valores dos índices de vegetação em plantas infestadas por bicho-mineiro que tendem a aumentar, visto que as mariposas do bicho-mineiro selecionam plantas com maior vigor vegetativo para ovopositar (Nestel et al., 2004).

A correlação negativa entre a incidência da cercosporiose e os índices de vegetação também pode estar associado ao teor de água nas plantas, pois segundo autores (Santos et al., 2004; Paiva et al., 2013; Vasco et al., 2015), destacam que os maiores índices de cercosporiose são encontrados em parcelas não irrigadas,

indicando influência positiva na disponibilidade de água para a planta na redução da incidência da doença. Nesse contexto, o maior valor de coeficiente de correlação apresentados por NDWI ( $r = -0,61$ ) pode estar relacionado a capacidade desse índice em detectar estresse hídrico nas plantas, uma vez que para o cálculo do NDWI, utiliza-se a banda do infravermelho médio, banda sensível ao teor de água nas plantas.

Os valores de coeficientes de correlação entre as características físicas, química e biológicas e os índices de vegetação foram positivos para matéria orgânica, silte e argila e negativos para pH e areia (Tabela 3).

**Tabela 3:** Coeficientes de correlação de Pearson ( $p < 0,01$ ) entre as características física, química e biológicas do solo em lavoura de cafeiro (*Coffea arabica*) em 04/02/2006 e índices de vegetação em 26/01/2006. Ijaci - MG, Brasil

Índices de Vegetação	pH	Matéria Orgânica	Areia	Silte	Argila
OSAVI	-0,34	0,43	-0,71	0,64	0,65
MSR	-0,34	0,44	-0,72	0,65	0,66
RDVI	-0,35	0,43	-0,71	0,64	0,65
MTVI1	-0,31	0,41	-0,71	0,64	0,66
NDWI	-0,13	0,58	-0,80	0,75	0,74
MTVI2	-0,39	0,30	-0,58	0,54	0,53
TVI	-0,29	0,42	-0,72	0,63	0,66
GARI	-0,15	0,34	-0,56	0,47	0,53
SAVI	-0,34	0,43	-0,71	0,64	0,65
SICI	-0,29	0,52	-0,79	0,69	0,73
MSAVI	-0,35	0,42	-0,70	0,64	0,64
MCARI1	-0,20	0,44	-0,69	0,59	0,64
MCARI2	-0,39	0,33	-0,61	0,57	0,56
NDVI	-0,34	0,43	-0,71	0,64	0,65
SR	-0,33	0,45	-0,73	0,66	0,67
GNDVI	-0,24	0,52	-0,75	0,67	0,69

Assim como para variável incidência da cercosporiose e infestação do bicho-mineiro, os valores de coeficiente de correlação entre os índices de

vegetação e as características do solo foram semelhantes para cada variável independente. O índice NDWI apresentou o maior valor de coeficiente de correlação com matéria orgânica ( $r = 0,58$ ), areia ( $r = -0,80$ ), silte ( $r = 0,75$ ) e argila ( $r = 0,74$ ), e os índices MTVI2 ( $r = 0,39$ ) e MCARI 2 ( $r = 0,39$ ), com a variável pH do solo.

A correlação positiva entre os índices de vegetação com o teor de matéria orgânica, silte a argila no solo e negativa com o teor de areia no solo pode estar associada a disponibilidade de nutrientes para as plantas. A textura do solo (areia, silte e argila) é um dos principais fatores responsáveis pela disponibilidade de nutrientes para as plantas. Solos com maiores teores de areia, devido ao tamanho de seus poros, tendem a lixiviar nutrientes com mais facilidade, como no caso do potássio (Melo et al., 2004). Em contrapartida, a fração silte e argila pode contribuir para o aumento da concentração de cálcio, magnésio e potássio, na solução do solo (Corrêa et al. 2003). Além disso, a capacidade troca de cátions (CTC) da matéria orgânica é fundamental para a CTC total do solo, sendo essencial na retenção de nutrientes e na diminuição da lixiviação (Silva et al., 2013). Sendo assim, de maneira geral, solos siltosos, argilosos e com teor de matéria orgânica elevado, propiciam melhores condições para o desenvolvimento das plantas quando comparados a solos arenosos. Nesse contexto, nas regiões da lavoura com maiores teores de matéria orgânica, silte e argila no solo, os cafeeiros, provavelmente, apresentavam maior vigor vegetativo e, consequentemente, maiores valores dos índices de vegetação. Em contrapartida, nas regiões com maiores teores de areia, os cafeeiros apresentavam menor vigor vegetativo e menores valores dos índices de vegetação.

Ainda sobre a textura do solo, a sensibilidade do NDWI a presença de água nas plantas pode ter contribuído para os maiores valores do coeficiente de correlação desse índice com a textura do solo quando comparado aos outros índices, pois conforme observado no estudo de Arruda et al. (1987), o teor de silte

e argila são relacionados com a retenção de água no solo e, portanto, maior disponibilidade de água para as plantas.

No caso do pH do solo, a correlação negativa com os índices de vegetação pode ter ocorrido em razão da predominância dos valores de pH na lavoura acima de 6,5 (Figura 2), visto que a disponibilidade de nutrientes para as plantas em solo com pH nessa faixa é menor (Moreira & Fageria, 2010). Dessa forma, regiões na lavoura com pH acima 6,5 podem ter contribuído para o menor vigor vegetativo dos cafeeiros e, consequentemente, menores valores dos índices de vegetação.

Os valores de coeficiente de correlação entre os índices de vegetação e o pH e textura do solo obtidos nesse estudo foram superiores aos encontrados em Tola et al. (2017). No estudo da produtividade da grama Rhodes na região oriental da Arábia Saudita, esses autores evidenciaram correlação negativa do NDVI com o pH ( $r = -0,11$ ) e positiva com silte ( $r = 0,32$ ), argila ( $r = 0,24$ ) e areia ( $r = 0,17$ ). Contudo, ressalta-se que a baixa variabilidade espacial da areia na área de estudo desses autores pode ter contribuído para a correlação positiva com o NDVI.

Os valores de coeficientes de correlação entre os macros e micronutrientes nas folhas e os índices de vegetação foram positivos para Mg, Cu, B e Mn e negativos para K e Fe (Tabela 4).

Apesar da maioria dos índices de vegetação terem apresentado valores de coeficientes de correlação semelhantes com as características do solo, o índice MTVI1 apresentou o maior valor de coeficiente para K ( $r = -0,403$ ), o NDWI para Mg ( $r = 0,511$ ), o SR para Cu ( $r = 0,595$ ) e Mn ( $r = 0,629$ ), o GARI para B ( $r = 0,508$ ) e o MSAVI para Fe ( $r = -0,753$ ).

A correlação positiva dos índices de vegetação com os nutrientes Mg, Cu, B e Mn nas folhas pode estar associado ao estresse nos cafeeiros provocado pelo desequilíbrio nutricional desses nutrientes. As plantas em condições de estresse reduzem a concentração de clorofila nas folhas, apresentam clorose e, consequentemente, diminuem a absorção de luz incidente na região espectral do

visível (Carter, 1993; Masoni et al., 1996; Carter & Knapp 2001; Zhao et al., 2003; Bratasevec et al., 2013). Portanto, os cafeeiros com desequilíbrios desses nutrientes podem ter apresentado maiores reflectâncias nas bandas do visível e dessa forma, reduzido os valores dos índices de vegetação. No caso da correlação negativa dos índices de vegetação com os nutrientes K e Fe, o equilíbrio nutricional desses nutrientes nos cafeeiros pode ter provocado o aumento da concentração de clorofila nas folhas e redução da reflectância nas bandas do visível, aumentando assim os valores dos índices de vegetação.

**Tabela 4:** Coeficientes de correlação de Pearson ( $p < 0,01$ ) entre macros e micronutrientes nas folhas em lavoura de cafeeiro (*Coffea arabica*) em 29/05/2006 e índices de vegetação em 18/05/2006. Ijaci - MG, Brasil

Índices de vegetação	K	Mg	Cu	B	Fe	Mn
OSAVI	-0,306	0,407	0,561	0,326	-0,748	0,624
MSR	-0,270	0,431	0,591	0,379	-0,710	0,627
RDVI	-0,312	0,402	0,552	0,317	-0,752	0,623
MTVII	-0,403	0,017	0,182	0,234	-0,650	0,568
NDWI	-0,146	0,511	0,403	0,426	-0,666	0,561
MTVI2	-0,356	0,353	0,545	0,292	-0,732	0,602
TVI	-0,381	0,012	0,115	0,279	-0,637	0,544
GARI	0,006	0,299	0,468	0,508	-0,261	0,094
SAVI	-0,303	0,407	0,561	0,326	-0,748	0,624
SICI	-0,289	0,389	0,513	0,301	0,740	0,559
MSAVI	-0,316	0,398	0,546	0,311	-0,753	0,623
MCARI1	-0,135	0,164	0,286	0,468	-0,528	0,110
MCARI2	-0,352	0,365	0,535	0,298	-0,739	0,611
NDVI	-0,303	0,407	0,561	0,326	-0,748	0,624
SR	-0,251	0,436	0,595	0,402	-0,679	0,629
GNDVI	-0,185	0,381	0,435	0,270	-0,709	0,322

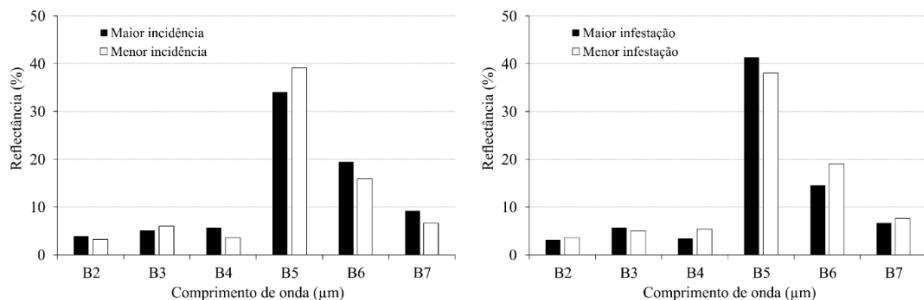
Pimstein et al. (2011), monitorando o estresse na cultura do trigo, também observaram correlações negativas de até  $r = -0,45$  dos nutrientes N, P e K com a

reflectância das plantas nos comprimentos de onda do visível. Esses autores concluíram que monitoramento de nutrientes em cultura pode ser usado com auxílio de dados de sensoriamento remoto. De forma semelhante, Mahajan et al. (2016) demonstraram que os índices de vegetação podem ser usados na predição e monitoramento das condições de N, P e S na cultura do arroz. Para isso, os autores reportaram correlações do N, P e S com os índices NDVI ( $r = 0,58, 0,34$  e  $0,37$ , respectivamente) e GNDVI ( $r = 0,47, 0,29$  e  $0,33$ , respectivamente). Entretanto, Serrano et al. (2017) obtiveram correlação não significativa entre o NDVI e os teores de sódio e potássio em plantação de vinhedo. Os autores explicaram que este comportamento é aceitável, visto que as plantas analisadas apresentavam concentrações adequada desses nutrientes. E, ainda, esses autores ponderaram que se espera que, em situações de deficiência de nutrientes de plantas, o vigor vegetativo da planta seja afetado (por exemplo, clorose das folhas), fenômeno esse detectado por sensores remotos.

Diante desse contexto, foi possível inferir que as plantas da lavoura de estudo, apresentavam deficiência nutricional de Mg, Cu, B e Mn e equilíbrio de K e Fe na época das análises.

### *Assinatura espectral*

Foi possível observar que a assinatura espectral dos cafeeiros com incidência da cercosporiose e infestação do bicho mineiro apresentaram reflectância espectral padrão do cafeiro, ou seja, alta reflectância na região espectral do infravermelho próximo ( $0,76$  a  $0,90\text{ }\mu\text{m}$ ) e forte absorção de energia nas regiões espectrais do visível ( $0,45$  a  $0,69\text{ }\mu\text{m}$ ) e infravermelho médio ( $1,55$  a  $2,35\text{ }\mu\text{m}$ ) (Figura 6).



**Figura 6:** Assinatura espectral das plantas infectadas com cercosporiose nas folhas (esquerda) e com infestação do bicho-mineiro nas folhas (direita) em lavoura cafeeira (*Coffea arabica*) derivadas de imagens Landsat 5/TM em 18/05/2006. Ijaci - MG, Brasil.

A reflectância nos cafeeiros com maior incidência de cercosporiose foi maior nos comprimentos de onda visível, exceto a banda verde (B3), e infravermelho médio, e menor no infravermelho próximo, quando comparadas com a reflectância nos cafeeiros com menor incidência da cercosporiose. Doenças em plantas, como a cercosporiose, podem causar modificações na cor do tecido e forma da folha, taxa de transpiração, morfologia e densidade do dossel da cultura, bem como variação na interação da radiação solar com as plantas nas regiões espectrais do visível e infravermelho (West et al., 2010). Essa diferença de reflectância nos comprimentos de onda do visível, infravermelho próximo e médio provocada por doenças no cafeiro também foi relatada por Chemura et al. (2016). Ao estudar a reflectância de folhas saudáveis e folhas infectadas por ferrugem, esses autores observaram maior reflectância na região espectral do infravermelho próximo e menor na região do visível nas folhas saudáveis do que nas folhas com diferentes níveis de infecção da doença. Além disso, essa diferença de reflectância também tem sido reportada por outros autores em diferentes doenças em plantas (Santos Júnior et al., 2002; Zhang et al., 2003; Prabhakar et al., 2011; Mirik et al., 2012; Huang et al., 2012; Mahlein et al., 2013; Garcia-Ruiz et al., 2013; Prabhakar et al., 2013; Martins & Galo 2014; Ashourloo et al., 2016).

No caso da reflectância nos cafeeiros de maior infestação do bicho-mineiro, houve menor reflectância nas bandas do visível, exceto a banda do verde (B3), e infravermelho médio e maior na banda do infravermelho próximo em relação à reflectância nos cafeeiros de menor infestação da doença. Apesar da mudança na reflectância ao longo do espectro eletromagnético dos cafeeiros com maior infestação do bicho-mineiro em relação aos cafeeiros com menor infestação, essa provavelmente não está relacionado à doença. De maneira oposta à cercosporiose, que causa desfolha intensa e alteração nas estruturas das folhas e dos cafeeiros, o bicho-mineiro necessita de cafeeiros com alto vigor vegetativo para a sobrevivência das larvas (Nestel et al., 1994). Caixeta et al. (2004) constataram que a adequada nutrição nitrogenada, o excesso de potássio, o aumento nos teores de proteínas, decréscimo nos teores de lignina, amido e açúcares solúveis totais nas folhas aumentaram a intensidade de infestação do bicho-mineiro em mudas de cafeiro. Além disso, Michereff (2000) também verificou que a hipótese do vigor da planta é válida para a interação bicho-mineiro com as plantas de cafeiro. Nesse contexto, a alteração da reflectância das plantas em função da maior ocorrência do bicho-mineiro, deve-se a preferência da praga por plantas bem nutritas, e não a danos causados na planta por essa.

## CONCLUSÕES

Este estudo demonstrou o potencial dos índices de vegetação derivados de imagens multiespectrais Landsat 5/TM em identificar e mapear o estresse nas plantas de café causados por variáveis ambientais bióticas e abióticas. Além disso, os resultados deste estudo podem contribuir para um gerenciamento mais eficientes das lavouras cafeiras, assim como para a sustentabilidade da atividade por meio do uso mais racional de fertilizantes e produtos fitossanitários.

## REFERÊNCIAS

- Ahamed T, Tian L, Zhang Y, Ting KC (2011) A review of remote sensing methods for biomass feedstock production. *Biomass and Bioenergy*, 35(7):2455-2469.
- Arruda FB, Zullo Junior J, Oliveira JB (1987) Parâmetros de solo para o cálculo da água disponível com base na textura do solo. *Revista Brasileira de Ciência do Solo*, 11(1):11-15.
- Ashourloo D, Matkan AA, Huete A, AGhigli H, Mobasher MR (2016) Developing an index for detection and identification of disease stages. *IEEE Geoscience and Remote Sensing Letters*, 13(6):851-855.
- Barton CVM (2012) Advances in remote sensing of plant stress. *Plant and Soil*, 354:41-44.
- Bernardes T, Moreira MA, Adami M, Giarolla A, Rudorff BFT (2012) Monitoring biennial bearing effect on coffee yield using MODIS remote sensing imagery. *Remote Sensing*, 4(9):2492-2509.
- Bernardi ACC, Célia RG, Ricardo GA, Ladislau MR, Ricardo YI (2017) Spatial variability of vegetation index and soil properties in an integrated crop-livestock system. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 21(8):513-518.
- Birth GS & Mcvey G (1968) Measuring the colour of growing turf with a reflectance spectrophotometer. *Agronomy Journal*, 60(6):640-643.
- Boldini JM (2001) Epidemiologia da ferrugem e da cercosporiose em cafeiro irrigado e fertirrigado. Dissertação de Mestrado. Universidade Federal de Lavras, Lavras. 67p.
- Bratasevec K, Sivilotti P, Vodopivec BM (2013) Soil and foliar fertilization affects mineral contents in *Vitis vinifera* L. cv. 'rebula' leaves. *Journal of soil science and plant nutrition*, 13(3):650-663.
- Broge NH & Leblanc E (2001) Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment*, 76(6):156- 172.

- Caixeta SL, Martinez HEP, Picanço MC, Cecon PR, Esposti MDD, Amaral JFT (2004) Leaf-miner attack in relation to nutrition and vigor of coffee-tree seedlings. Ciência Rural, 34(5):1429-1435.
- Cantarutti RB, Alvarez V, Ribeiro AC (1999) Amostragem do solo. In: Ribeiro AC, Guimarães PTG, Alvarez V (Eds). Recomendação para uso de corretivos e fertilizantes em Minas Gerais: 5<sup>a</sup> aproximação. CFSEMG, Viçosa. p.13-20.
- Carter GA & Knapp AK (2001) Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. American journal of botany, 88(4):677-684.
- Carter G.A (1993) Responses of leaf spectral reflectance to plant stress. American Journal of Botany, 80:239-243.
- Corrêa MM, Ker JC, Mendonça, ES, Ruiz HA, Bastos RS (2003). Physical, chemical and mineralogical characteristics of soils from the meadow region of sousa (PB). Revista Brasileira de Ciência do Solo, 27(2):311-324.
- Chemura A, Mutanga O, Dube T (2016) Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. Precision Agriculture, 18(5):859-881.
- Chemura A, Mutanga O, Dube T (2017) Integrating age in the detection and mapping of incongruous patches in coffee (*Coffea arabica*) plantations using multi-temporal Landsat 8 NDVI anomalies. International Journal of Applied Earth Observation and Geoinformation, 57:1-13.
- Chen JM (1996) Evaluation of vegetation indices and a modified simple ratio for boreal applications. Canadian Journal of Remote Sensing, 22:229-242.
- Eitel JU, Gessler PE, Smith AM, Robberecht R (2006) Suitability of existing and novel spectral indices to remotely detect water stress in *Populus* spp. Forest Ecology and Management, 229(1):170-182.
- Gao B (1996) NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. Remote sensing of environment, 58(3):257-266.
- Garcia-Ruiz F, Sankaran S, Maja JM, Lee WS, Rasmussen J, Ehsani R (2013) Comparison of two aerial imaging platforms for identification of

- Huanglongbing-infected citrus trees. Computers and Electronics in Agriculture, 91:106-115.
- Gitelson AA, Kaufman YJ, Merzlyak MN (1996) Use of a green channel in remote sensing of global vegetation from EOS-MODIS. Remote Sensing of Environment, 58(3):289-298.
- Haboudane D, Miller JR, Pattey E, Zarco-Tejada PJ, Strachan IB (2004) Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modelling and validation in the context of precision agriculture. Remote Sensing of Environment, 90(3):337- 352.
- Hillnhütter C, Mahlein AK, Sikora RA, Oerke EC (2011) Remote sensing to detect plant stress induced by *Heterodera schachtii* and *Rhizoctonia solani* in sugar beet fields. Field Crops Research, 122(1):70-77.
- Huang J, Liao H, Zhu Y, Sun J, Sun Q, Liu X (2012) Hyperspectral detection of rice damaged by rice leaf folder (*Cnaphalocrocis medinalis*). Computers and electronics in agriculture, 82:100-107.
- Huerta AS (1963) Par de folhas representativo del estado nutricional del cafeto. Cenicafé 14(1):11-127
- Huete ARA (1988) Soil adjusted vegetation index (SAVI). Remote Sensing of Environment, 25(3):295-309.
- Li G, Wan S, Zhou J, Yang Z, Qin P (2010) Leaf chlorophyll fluorescence, hyperspectral reflectance, pigments content, malondialdehyde and proline accumulation responses of castor bean (*Ricinus communis* L.) seedlings to salt stress levels. Industrial crops and products, 31(1):13-19.
- Liu ZY, Huang JF, Tao RX (2008) Characterizing and estimating fungal disease severity of rice brown spot with hyperspectral reflectance data. Rice Science, 15(3):232-242.
- Mahajan GR, Pandey RN, Sahoo RN, Gupta VK, Datta SC, Kumar D (2016) Monitoring nitrogen, phosphorus and sulphur in hybrid rice (*Oryza sativa* L.) using hyperspectral remote sensing. Precision Agriculture, 18(5):736-761.
- Mahajan GR, Sahoo RN, Pandey RN, Gupta VK, Kumar D (2014) Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus,

sulphur and potassium in wheat (*Triticum aestivum* L.). Precision agriculture, 15(5):499-522.

Mahlein AK, Rumpf T, Welke P, Dehne HW, Plümer L, Steiner U, Oerke EC (2013) Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128:21-30.

Malavolta E, Vitti GC, Oliveira AS (1997) Avaliação do estado nutricional das plantas: princípios e aplicações. Potafós, Piracicaba. 319p.

Martins GD & Galo MDLBT (2014) Detection of Infested Areas by Nematodes and *Migdolus Fryanus* in Sugarcane from Rapideye Multispectral Images. *Revista Brasileira de Cartografia*, 1(66/2):285-301.

Masoni A, Ercolli L, Mariotti M (1996) Spectral properties of leaves deficient in iron, sulfur, magnesium, and manganese. *Agronomy jornal*, 88:937-943.

Melo VF, Ribeiro NA, Maschio PA, Corrêa GF, Lima VC (2004) Mineralogy and forms of K and Mg in different weight and size classes of sand fraction of Triângulo Mineiro soils, Minas Gerais State, Brazil. *Revista Brasileira de Ciência do Solo*, 28(2):219-231.

Michereff MFF (2000) Comportamento reprodutivo do bichomineiro do cafeeiro, *Leucoptera coffeella* (Guérin-Mèneville, 1842) (Lepidoptera : Lyonetiidae). Dissertação de Mestrado. Universidade Federal de Viçosa, Viçosa. 46p.

Mirik M, Michels GJ, Kassymzhanova-Mirik S, Elliott NC, Bowling R (2006) Hyperspectral spectrometry as a means to differentiate uninfested and infested winter wheat by greenbug (Hemiptera: Aphididae). *Journal of economic entomology*, 99(5):1682-1690.

Mirik M, Norland JE, Biondini ME, Crabtree RL, Michels GJ (2007) Relationships between remotely sensed data and biomass components in a big sagebrush (*Artemisia tridentata*) dominated area in Yellowstone National Park. *Turkish Journal of Agriculture and Forestry*, 31(2):135-145

Mirik M, Jones DC, Price JA, Workneh F, Ansley RJ, Rush CM (2011) Satellite remote sensing of wheat infected by wheat streak mosaic virus. *Plant Disease*, 95(1):4-12, 2011.

- Mirik M, Ansley RJ, Michels GJ, Elliott NC (2012) Spectral vegetation indices selected for quantifying Russian wheat aphid (*Diuraphis noxia*) feeding damage in wheat (*Triticum aestivum* L.). Precision agriculture, 13(4):501-516.
- Moreira A & Fageria NK (2010) Liming influence on soil chemical properties, nutritional status and yield of alfalfa grown in acid soil. Revista Brasileira de Ciência do Solo, 34(4):1231-1239.
- Moreira MA, Adami M, Rudorff BFT (2004) Spectral and temporal behavior analysis of coffee crop in Landsat images. Pesquisa Agropecuária Brasileira, 39(3):223-231.
- Motomiya AVA, Molin JP, Motomiya WR, Baio FHR (2012) Mapeamento do índice de vegetação da diferença normalizada em lavoura de algodão. Pesquisa Agropecuária Tropical, 42(1):112-118.
- Nestel D, Dickschen F, Altieri MA (1994) Seasonal and spatial population loads of a tropical insect: the case of the coffee leaf-miner in Mexico. Ecological Entomology, 19(2):159-167.
- Ortiz BV, Thomson SJ, Huang Y, Reddy KN, Ding W (2011) Determination of differences in crop injury from aerial application of glyphosate using vegetation indices. Computers and electronics in agriculture, 77(2):204-213.
- Paiva BRTL, De Souza PE, Scalco MS, Monteiro FP (2013) Progress of cercospora leaf spot in coffee under different irrigation management systems and planting densities. Coffee Science, 8(2):166-175.
- Peñuelas J, Baret F, Filella I (1995) Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. Photosynthetica, 31(2):221-230.
- Pimstein A, Karnieli A, Bansal SK, Bonfil DJ (2011) Exploring remotely sensed technologies for monitoring wheat potassium and phosphorus using field spectroscopy. Field Crops Research, 121(1):125-135.
- Prabhakar M, Prasad YG, Desai S, Thirupathi M, Gopika K, Rao GR, Venkateswarlu B (2013) Hyperspectral remote sensing of yellow mosaic severity and associated pigment losses in *Vigna mungo* using multinomial logistic regression models. Crop protection, 45:132-140.

- Prabhakar M, Prasad YG, Thirupathi M, Sreedevi G, Dharajothi B, Venkateswarlu B (2011) Use of ground based hyperspectral remote sensing for detection of stress in cotton caused by leafhopper (Hemiptera: Cicadellidae). *Computers and Electronics in Agriculture*, 79(2):189-198.
- Qi J, Chehbouni A, Huete AR, Kerr YH, Sorooshian SA (1994) Modified soil adjusted vegetation index. *Remote Sensing of Environmental*, 48(2):119-126.
- Rondeaux G, Steven M, Baret F (1996) Optimization of soil-adjusted vegetation indices. *Remote sensing of environment*, 55(2):95-107.
- Roujean JL & Breon FM (1995) Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3):375-384.
- Rouse JW, Haas RH, Schell JA, Deering DW, Harlan JC (1974) Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. Greenbelt: NASA/GSFC, Type III, Final Report. 371p.
- Santos Junior RF, Santos JM, Rudorff BF, Marchiorato IA (2002) Detection of infested areas with Heterodera glycines in a soybean field using spectroradiometry in the visible and near infrared. *Fitopatologia Brasileira*, 27:355-360.
- Santos FS, Souza PE, Pozza EA (2004) Epidemiologia da cercosporiose em cafeeiro (*Coffea arabica* L.) fertirrigado. *Summa Phytopathologica*, 30(1):31-37.
- Santos WJR, Silva BM, Oliveira GC, Volpato MML, Lima JM, Curi N, Marques JJ (2014) Soil moisture in the root zone and its relation to plant vigor assessed by remote sensing at management scale. *Geoderma*, 221:91-95.
- Serrano J, Silva J, Shahidian S, Silva LL, Sousa A, Baptista F (2017) Differential vineyard fertilizer management based on nutrient's spatio-temporal variability. *Journal of soil science and plant nutrition*, 17(1):46-61.
- Silva VMD, Teixeira AFR, Reis EFD, Benassi AC, Mendonça EDS (2013) Chemical attributes of soil organic fertilizer on systems of coffee conilon. *Coffee Science*, 8(4):69-477.

- Subash N, Mohan HSR, Banukumar K (2011) Comparing water-vegetative indices for rice (*Oryza sativa* L.)–wheat (*Triticum aestivum* L.) drought assessment. Computers and electronics in agriculture ,77(2):175-187.
- Tola E, Al-gaadi KA, Madugundu R, Zeyada AM, Kayad AG, Biradar CM (2017) Characterization of spatial variability of soil physicochemical properties and its impact on Rhodes grass productivity. Saudi journal of biological sciences, 24(2):421-429.
- Usda (2017) Coffee: World Markets and Trade Foreign Agricultural. Disponível em: <http://usda.mannlib.cornell.edu/usda/fas/tropprod//2010s/2016/tropprod-12-16-2016.pdf>. Acessado em: 04 de janeiro de 2018.
- Valencia AG (1970) Estudio fisiológico de la defoliación causado por *Cercospora coffeicola* en el cafeto. Cenicafé (Colombia), 21(3):105-114.
- Vasco GB, Pozza EA, Scalco MS, Santos LSD, Custódio AAP, Silva MLO (2015) Brown eye spot incidence in fruits of coffee: different density planting and water managements. Coffee Science, 10(1):38-45.
- West JS, Bravo C, Oberti R, Moshou D, Ramon H, McCartney HA (2010) Detection of Fungal Diseases Optically and Pathogen Inoculum by Air Sampling. In: Oerke EC., Gerhards R., Menz G., Sikora R. (Eds). Precision Crop Protection - the Challenge and Use of Heterogeneity. Netgerlands, Springer. p.135-149.
- Zambolim L, Vale FXR, Pereira AA, Chaves GM (1997) Café (*Coffea arabica* L.), controle de doenças causadas por fungos, bactérias e vírus. In: Vale FXR, Zambolim L (Ed). Controle de doenças de plantas. Viçosa, Suprema Gráfica e Editora. p.83-180.
- Zanzarini FV, Pissarra TC, Brandão FJ, Teixeira DD (2013) Spatial correlation of the vegetation index (NDVI) of a Landsat/ETM+ images with soil attributes. Revista Brasileira de Engenharia Agrícola e Ambiental, 17(6):608–614.
- Zhao D, Reddy, KR, Kakani VG, Read JJ, Carter GA (2003) Corn (*Zea mays* L.) growth, leaf pigment concentration, photosynthesis and leaf hyperspectral reflectance properties as affected by nitrogen supply. Plant and soil, 257:205-218.
- Zhang M, Qin Z, Liu X, Ustin SL (2003) Detection of stress in tomatoes induced by late blight disease in California, USA, using hyperspectral remote

sensing. International Journal of Applied Earth Observation and Geoinformation, 4(4):295-310.