



JULIA DAL POGGETTO RODRIGUES

**ANÁLISE ESPAÇOTEMPORAL DA SIGATOKA
AMARELA DA BANANEIRA UTILIZANDO
SENSORIAMENTO REMOTO E
GEOESTATÍSTICA**

LAVRAS – MG

2017

JULIA DAL POGGETTO RODRIGUES

**ANÁLISE ESPAÇOTEMPORAL DA SIGATOKA AMARELA DA
BANANEIRA UTILIZANDO SENSORIAMENTO REMOTO E
GEOESTATÍSTICA**

Dissertação apresentada à
Universidade Federal de Lavras,
como parte das exigências do
Programa de Pós-Graduação em
Engenharia Agrícola, área de
concentração em Engenharia
Agrícola, para a obtenção do título
de Mestre.

Orientador

Prof. Dr. Marcelo de Carvalho Alves

Coorientador

Prof. Dr. Edson Ampélio Pozza

LAVRAS – MG

2017

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

Rodrigues, Julia Dal Poggetto.

Análise espaçotemporal da Sigatoka amarela da bananeira
utilizando sensoriamento remoto e geoestatística / Julia Dal
Poggetto Rodrigues. - 2017.

87 p.

Orientador(a): Marcelo de Carvvalho Alves.

Coorientador(a): Edson Ampélio Pozza.

Dissertação (mestrado acadêmico) - Universidade Federal de
Lavras, 2017.

Bibliografia.

1. Índices de vegetação. 2. Gneiting. 3. *Mycosphaerella
musicola*. I. Alves, Marcelo de Carvvalho. II. Pozza, Edson
Ampélio. III. Título.

JULIA DAL POGGETTO RODRIGUES

**ANÁLISE ESPAÇOTEMPORAL DA SIGATOKA AMARELA DA
BANANEIRA UTILIZANDO SENSORIAMENTO REMOTO E
GEOESTATÍSTICA**

Dissertação apresentada à
Universidade Federal de Lavras,
como parte das exigências do
Programa de Pós-Graduação em
Engenharia Agrícola, área de
concentração em Engenharia
Agrícola, para a obtenção do título
de Mestre.

Aprovada em 14 de setembro de 2017.

Dr. Marcelo de Carvalho Alves	UFLA
Dr. Marcelo Silva de Oliveira	UFLA
Dr. Aurivan Soares de Freitas	Unincor

Orientador

Prof. Dr. Marcelo de Carvalho Alves

LAVRAS – MG

2017

*Deus, Senhor da Vida, pela presença constante em meu viver.
Aos meus pais, Renato e Fernanda, pelo amor e compreensão.
Ao meu irmão, Gabriel, pelo companheirismo, incentivo e amizade.
Ao meu sobrinho Pedro, por todo amor e alegria.*

DEDICO

AGRADECIMENTOS

À Universidade Federal de Lavras, em especial ao Departamento de Engenharia Agrícola, pela oportunidade de aperfeiçoar meus conhecimentos.

Ao CNPq, pela bolsa de estudos, que proporcionou a ação desta pesquisa.

Ao professor Marcelo de Carvalho Alves, pela orientação e pela oportunidade a mim concedida, pela paciência e pelos conhecimentos compartilhados.

Ao professor Edson Ampélio Pozza, pela coorientação, atenção e disponibilidade dos dados analisados nessa dissertação.

Ao professor Aurivan Soares de Freitas, pela atenção ímpar durante as explicações atinentes à pesquisa.

Ao professor Marcelo Silva de Oliveira, pela atenção, apoio e por esclarecer minhas dúvidas.

Ao professor Fausto Weimar Acerbi Jr., pelas valiosas contribuições na qualificação.

Aos professores Fernando Shinji Kawakubo, Rúbia Gomes Morato e à pesquisadora Margarete Marin Lordelo Volpato, pela iniciação inspiradora com o trabalho de sensoriamento remoto, o qual me levou a trilhar este caminho de pesquisa.

Aos funcionários do DEG e da UFLA, pelos serviços prestados, em especial a Helem, sempre atenciosa e prestativa.

Ao Henrique, pela ajuda e apoio com a rotina geoestatística.

Aos meus colegas e amigos do laboratório de geoprocessamento e sensoriamento remoto: Chris, Diego, Filipe, Franklin, Jefferson, Matheus,

Michel, Miryan e Tales pela parceria, apoio, auxílio no trabalho e pelos momentos de descontração.

Às minhas amigas de república, Valéria e Laura, pelo convívio diário, paciência e compreensão.

À minha amiga Priscilla, pelo incentivo, companheirismo e amizade.

Muito obrigada!

RESUMO GERAL

A Sigatoka amarela, cujo agente etiológico é o *Pseudocercospora musae* (*Mycosphaerella musicola*), está entre as doenças que mais afetam a bananeira. O progresso da doença ocorre tanto no tempo como no espaço e as ciências Sensoriamento Remoto e Geoestatística espaço-tempo oferecem suporte para a análise desse processo dinâmico. Portanto, o objetivo deste trabalho foi realizar a predição espaçotemporal da Sigatoka amarela em diferentes épocas, calcular e avaliar índices de vegetação derivados do sensor Enhanced Thematic Mapper Plus (ETM+), satélite Landsat 7, para inferir sobre a ocorrência da doença, avaliar a existência de correlação espacial e temporal entre dados obtidos pelo sensor e dados *in situ* e, por fim, analisar a assinatura espectral da planta afetada pela doença. No primeiro estudo, foram utilizadas imagens do satélite Landsat 7, sensor ETM+, com correção atmosférica método Dark Object Substraction 1 (DOS1) e Second Simulation of Sattelite Signal in the Solar Spectrum (6S). Foram calculados os índices Vegetação da Diferença Normalizada (NDVI), Índice de Vegetação da Diferença Normalizada no Verde (GNDVI) e Índice de Água de Diferença Normalizada (NDWI). Na assinatura espectral referente aos meses de setembro e outubro, a região do infravermelho médio possibilitou a análise das características da doença na planta. Os índices NDVI e GNDVI mostraram diferenças na correção atmosférica e em relação à doença o NDWI foi o que apresentou melhor resultado. No segundo estudo, os modelos de covariância espaçotemporais separáveis, Duplamente Exponencial, e não separáveis, de Gneiting, foram testados com os métodos de ajuste Weight Least Squares (WLS), Restricted Maximum Likelihood (REML) e Likelihood Pairwise. O modelo não separável de Gneiting, método de ajuste WLS, em que a tendência foi modelada, permitiu reduzir as incertezas de predição espacial e temporal da doença, bem como caracterizar o padrão espaçotemporal do monociclo da doença.

Palavras-chave: *Musa* spp.. *Mycosphaerella musicola*. Landsat 7 ETM+. Índices de vegetação. Gneiting.

GENERAL ABSTRACT

Yellow Sigatoka leaf spot, caused by *Pseudocercospora musae* (*Mycosphaerella musicola*), is among the diseases that most affect banana crop. The disease progress occurs in both time and space, and the Remote Sensing sciences and the space-time Geostatistics provide support for the analysis of this dynamic process. Therefore, the objective of this study was to perform the spatiotemporal prediction of yellow Sigatoka at different times, to calculate and evaluate vegetation indices derived from the Enhanced Thematic Mapper Plus (ETM+) sensor, from the Landsat 7 satellite, to infer about the disease occurrence, to evaluate the existence of spatial and temporal correlation between data obtained by the sensor and data *in situ*, and finally to analyze the spectral signature of the plant affected by the disease. The first study used images from the Landsat 7 satellite, ETM+ sensor, with atmospheric correction method Dark Object Subtraction 1 (DOS1) and Second Simulation of Satellite Signal in the Solar Spectrum (6S). Normalized Difference Vegetation Index (NDVI), Green Standard Difference Vegetation Index (GNDVI) and Normalized Difference Water Index (NDWI) were calculated. In the spectral signature related to the months of September and October, the mid-infrared region allowed the characterization of the disease in the plant. The NDVI and GNDVI indices showed differences in the atmospheric correction and in relation to the disease the NDWI presented better result. In the second study, Gneiting's separable spatiotemporal, Double Exponential, and non-separable covariance models were tested with the Weight Least Squares (WLS), Restricted Maximum Likelihood (REML) and Likelihood Pairwise methods. The Gneiting's non-separable model, WLS adjustment method, in which the trend was modeled, allowed to reduce as uncertainties of spatial and temporal prediction of the disease, as well as to characterize the pattern of monocycle temporality of the disease.

Keywords: *Musa* spp., *Mycosphaerella musicola*. Landsat 7 ETM+. Vegetation index. Gneiting.

SUMÁRIO

PRIMEIRA PARTE	10
1 INTRODUÇÃO.....	10
2 REFERENCIAL TEÓRICO	12
2.1 A cultura da bananeira e a Sigatoka amarela	12
2.2 Sensoriamento Remoto.....	15
2.3 Geoestatística.....	20
REFERÊNCIAS.....	24
SEGUNDA PARTE - ARTIGOS.....	31
ARTIGO 1	31
Caracterização Espectral e Temporal da Sigatoka amarela na cultura da bananeira	31
ARTIGO 2	62
Modelagem geoestatística de funções de covariância espaçotemporal estacionárias da Sigatoka amarela em cultura de bananeira	62

PRIMEIRA PARTE

1 INTRODUÇÃO

A bananeira (*Musa* spp.) é cultivada em países tropicais e o seu fruto, a banana, está entre as frutas mais consumidas, em virtude de suas vitaminas, carboidratos e sabor agradável, além de exercer um importante papel socioeconômico na geração de empregos e renda (FIORAVANÇO, 2003).

Dentre as doenças que afetam a bananeira, a Sigatoka amarela, cujo agente etiológico é o fungo *Mycosphaerella musicola* Leach na fase sexuada ou *Pseudocercospora musae* na fase assexuada, está entre as mais destrutivas (CORDEIRO; MATOS, 2005). Atualmente, a doença ocorre em todas as áreas produtoras de banana do Brasil, reduzindo a área fotossintetizante da planta e, conseqüentemente, a produção e a qualidade do fruto (CASTELAN et al., 2013).

A ocorrência da doença depende da interação dos fatores: patógeno, ambiente favorável, planta susceptível e tipo de manejo utilizado. De acordo com os autores Pozza e Pozza (2012), a questão nutricional também é um fator que influencia, visto que o excesso ou a deficiência podem levar a planta a apresentar predisposição ao ataque de doenças.

Para verificar o progresso da Sigatoka amarela, que ocorre no tempo e no espaço, ciências como o sensoriamento remoto e a geoestatística fornecem ferramentas que auxiliam a análise espaçotemporal desse processo dinâmico.

O sensoriamento remoto apresenta um grande potencial no levantamento de dados, no monitoramento e no planejamento agrícola (EPIPHANIO et al., 1994; DALLEMAND et al.; 1988). Além disso,

pode ser utilizado na quantificação, na detecção e no monitoramento de plantas infectadas de forma rápida e eficiente, contribuindo na redução de riscos de poluição por agrotóxicos e para uma melhor produtividade de grãos (NAUE et al., 2010). Ademais, com o processamento e a análise dos dados provindos do vasto acervo de imagens orbitais, disponíveis de maneira gratuita, o produtor detém uma alternativa economicamente viável ao planejamento da sua lavoura.

A geoestatística apresenta técnicas que são capazes de analisar e monitorar os processos ambientais e agrícolas (ALVES et al., 2012). Na análise de processos dinâmicos espaçotemporais, como o progresso da Sigatoka amarela, é preciso modelar as dependências resultantes desses processos (MONTERO; FERNÁNDEZ-AVILÉS, 2015). Entre os modelos geoestatísticos de covariância, que trabalham com essas questões, há os modelos que permitem isolar a parte somente espacial da parte somente temporal, chamados de separáveis e os modelos que visam capturar a interação espaçotemporal através da parametrização, como o modelo de Gneiting (2002).

São poucos os trabalhos que utilizam dados de imagens orbitais ou que analisam a magnitude da dependência espaçotemporal por modelos geoestatísticos, principalmente no caso dos dados orbitais, os quais trariam um custo benefício melhor para os produtores do que as pesquisas tradicionais de campo. Por isso, estudos relacionados à análise dessa doença são de grande importância, não só para o auxílio ao produtor, mas também para a realização de um controle ambientalmente consciente.

Dessa forma, o objetivo desse trabalho foi realizar a predição espaçotemporal da Sigatoka amarela em diferentes épocas, calcular e

avaliar os índices de vegetação derivados do sensor ETM+, satélite Landsat 7, para inferir sobre a ocorrência da doença, avaliar a existência de correlação espacial e temporal entre os dados obtidos pelos sensores e os dados *in situ* e por fim analisar a assinatura espectral da planta afetada pela doença.

2 REFERENCIAL TEÓRICO

2.1 A cultura da bananeira e a Sigatoka amarela

A cultura da bananeira apresenta importância socioeconômica por ser produzida por pequenos, médios e grandes produtores e também pelo fato de a banana ser uma fruta rica em sais minerais e potássio e, por isso, consumida pelas mais diversas classes sociais (FIORAVANÇO, 2003).

Segundo os dados da Food and Agriculture Organization of the United Nations Statistics Division (2017), a produção mundial de banana, em 2014, foi de 126,22 milhões de toneladas, e o Brasil destaca-se como o quarto maior produtor mundial. De acordo com o Instituto Brasileiro de Geografia e Estatística (2017), a produção, em 2015, foi aproximadamente de sete milhões de toneladas, e o estado de Minas Gerais está entre os maiores produtores (796 mil toneladas).

A bananeira é uma planta que se adapta a diversos tipos de solos, de preferência a planos, profundos e com um bom nível de aeração (BORGES; SOUZA, 2004). Por ser uma planta tipicamente tropical, apresenta um melhor desenvolvimento em locais, cuja temperatura se aproxima dos 28°C e a precipitação anual de 1.900mm bem distribuída ao longo do ano (CRISÓSTOMO; NAUMOV, 2009).

Para que a planta cresça e se desenvolva de maneira rápida e alcance maiores produções, é preciso uma nutrição mineral

balanceada, ou seja, que haja concentração adequada de nutrientes no solo (SILVA; SILVA; PEREIRA, 2011). Além de aumentar a produção, a quantidade adequada de macro e micronutrientes aumenta a resistência às doenças, tornando-se um método alternativo de manejo (POZZA; POZZA, 2012).

As pragas e as doenças da cultura prejudicam o bom desenvolvimento da cultura da bananeira, acarretando severas perdas na produção. Uma das estratégias para a solução desse problema é a criação de novas variedades resistentes mediante ao melhoramento genético, o qual possibilita a obtenção de híbridos superiores (SILVA; FLORES; NETO, 2002). Outra forma para evitar os problemas relacionados a doenças são as práticas de manejo agrícolas adequadas ao pomar. Tais práticas garantem condições essenciais para que se tenha um ambiente equilibrado, saudável e que levará à obtenção de frutos de qualidade superior e de maior lucro para os produtores (BORGES; SOUZA, 2004; EPAGRI, 2016).

Dentre as doenças que afetam a bananeira, a Sigatoka amarela, cujo agente etiológico é o fungo *P. musae* (Zimm.) Deighton na fase assexuada e *M. musicola* Leach na fase sexuada, está entre as mais destrutivas (CORDEIRO; MATOS; KIMATI, 2016). A doença foi descrita pela primeira vez em Java, no ano de 1902. Já os primeiros prejuízos de importância foram relatados nas Ilhas Fiji, vale de Sigatoka, em 1913. No Brasil, foi constatada inicialmente no Estado do Amazonas em 1944, estendendo-se, posteriormente, a todos os estados brasileiros (KIMATI et al., 2016).

Disseminada em todas as regiões do Brasil e do mundo, a doença é responsável pela redução da área foliar verde da planta, o que ocasiona uma redução no número de pencas, no tamanho do fruto,

além da maturação precoce, podendo acarretar perdas de 50 a 100%, dependendo do microclima (CORDEIRO; MATOS, 2005).

A disseminação da doença a longas distâncias ocorre por meio dos ascósporos e a curtas distâncias por meio dos conídios (TOLLENAR, 1995). Os esporos sexuais (ascósporos) de *M. musicola* são produzidos em pseudotécios, que se apresentam em forma de frasco com uma parede espessa marrom-escuro e ostíolo espesso bem definido, que emerge através dos estômatos. Os esporos assexuais são produzidos em esporodóquios, que se originam na câmara subestomática, formando um corpo estomático marrom-escuro ou preto, sobre o qual se desenvolvem os conidióforos curtos emergidos através da abertura do estômato (CORDEIRO; MATOS; KIMATI, 2005). A disseminação ocorre através da água da chuva, do orvalho, do vento e do material propagativo (VENTURA; HINZ, 2002).

Os primeiros sintomas da doença observados nos bananais são caracterizados por uma leve descoloração com forma de ponto entre as nervuras secundárias da segunda até a quarta folha. Este ponto amplia-se, formando os sinais com estrias de coloração amarela. Com a evolução da doença, as estrias crescem e formam manchas necróticas, elípticas, alongadas, dispostas paralelamente às nervuras secundárias da folha, desenvolvendo-se, por fim, uma lesão com o centro de coloração cinza, circundada por um halo amarelo. Em estádios avançados da doença, uma grande área foliar é comprometida, levando à morte prematura das folhas (VENTURA; HINZ, 2002).

Assim, faz-se necessário o monitoramento dessa doença de difícil controle, que atinge uma das frutas mais consumidas mundialmente e de grande importância social e econômica. Há três

tipos de controle da doença, o cultural, o químico e o genético. A utilização de variedades resistentes, por meio do controle genético, por não causar impacto ao ambiente deve ser preferida, mesmo sendo difícil aliar a resistência às doenças e o gosto agradável para o consumo (COORDEIRO; MATOS, 2005). Com isso, a aplicação de fungicidas acaba sendo a medida adotada no manejo da doença, o que acaba acarretando um aumento no custo da produção. Além disso, o uso indevido pode causar contaminação tanto humana, quanto ambiental (FREITAS, 2016).

2.2 Sensoriamento Remoto

O sensoriamento remoto é uma ciência que permite obter dados da superfície terrestre por meio da captação e do registro da energia eletromagnética refletida ou emitida pela superfície (FLORENZANO, 2007; ROSA, 2005). Possibilita também a obtenção de informações sobre as condições do solo e da cultura dos campos agrícolas de maneira eficaz (MORAN; INOUE; BARNES, 1997) em rápidas avaliações de áreas extensas por um custo relativamente baixo, quando comparado com pesquisa de campo tradicional, tornando-se um atraente método de captura de informações.

As aplicações de sensoriamento remoto vão desde o monitoramento de fenômenos até a previsão de safras agrícolas (JENSEN, 2009; LIU, 2006). Além disso, ele também pode auxiliar na redução do impacto ambiental e financeiro das práticas de manejo, uma vez que ao redirecionar a tecnologia agrícola, podem-se criar estratégias mais sustentáveis em longo prazo (BASSOI et al., 2014), visto que a agricultura é uma atividade dinâmica, que necessita frequentemente de monitoramento, e os dados gerados pelo

sensoriamento remoto fornecem informação rápida e precisa para o produtor (SEELAN et al., 2003).

Em estudos de doenças de plantas, o sensoriamento remoto, além de ser utilizado para a quantificação, pode servir para a detecção e o monitoramento de plantas infectadas e/ou áreas atacadas por fitopatógenos de forma rápida e eficiente, contribuindo na redução de riscos de poluição por agrotóxicos e para uma melhor produtividade (NAUE et al., 2010).

2.2.1 Assinatura espectral da vegetação

A qualidade e a quantidade da radiação refletida das plantas dependem de fatores como a sanidade do tecido vegetal que, ao serem infectados por fitopatógenos, reagem alterando a característica espectral da planta, o que permite a detecção de doenças em plantas pelo sensoriamento remoto (NAUE et al., 2010).

A aplicação da reflectância para fins agrícolas teve início nos anos de 1970, quando espectrômetros de infravermelho foram usados para medir a clorofila em folhas de plantas (LUKINA et al., 1997). A reflectância da cultura pode ser medida por radiômetros, que operam em bandas espectrais específicas, ou avaliada por meio de imagens orbitais, aéreas ou obtidas a partir de equipamentos agrícolas (visão artificial) (SENA JÚNIOR et al., 2008).

Em plantas fotossinteticamente ativas, ou seja, saudáveis, a resposta espectral na região do visível do espectro eletromagnético corresponde a uma baixa reflectância devido à absorção da radiação incidente pela clorofila e pelos carotenoides. Na região do infravermelho próximo, ocorre uma alta reflectância devido, à estrutura celular da folha (PONZONI; SHIMABUKURO, 2010).

O comportamento espectral de uma folha na região do visível (0,5 a 0,75 μ m) é responsável por 90% de absorção da radiação pelos pigmentos, 2% de transmitância e 8% de reflectância (LIU, 2006). Além disso, a resposta espectral nessa região é dominada pela ação dos pigmentos fotossintetizantes, pigmentos esses geralmente encontrados nos cloroplastos. A concentração desses pigmentos pode variar de espécie para espécie (MOREIRA, 2007; PONZONI; SHIMABUKURO, 2007). Na cultura do milho infectado pela mancha foliar (*Cercospora zea-maydis*), os autores Dhau et al. (2017) utilizaram imagens de alta e média resolução para a classificação em moderado e severamente infectado e a região do vermelho discriminou bem as categorias da infecção.

Na região do infravermelho próximo (0,75 a 1,35 μ m), a vegetação apresenta 55% de reflectância, 40% de transmitância e 5% de absorção (LIU, 2006). Nessa região, a vegetação apresenta alta reflectância em função das estruturas celulares com dimensões do comprimento de onda da radiação incidente, devido a não utilização dessa radiação nos processos de crescimento das plantas. O espalhamento da radiação nesta porção do espectro eletromagnético é utilizado como um processo de resfriamento da folha, evitando o acúmulo de energia no interior da mesma (NOBEL, 1999). O comprimento de onda do infravermelho próximo é muito utilizado em estudos relacionados a culturas infectadas como a do feijão, pelo fungo *Sclerotinia sclerotiorum* causador do mofo-branco (BOECHAT et al., 2014), da cana de açúcar, pela larva do besouro *Migdolus fryanus* (MARTINS; GALO, 2015), a do algodão, por percevejo castanho, *Scaptocoris castânea* (MOTOMIYA et al., 2012), e da soja, pela ferrugem asiática da soja (*Glycine max* L.) (SILVA et al., 2009).

Na região do infravermelho médio (1,3 a 2,6 μm), ocorre a absorção de radiação pela presença de água, principalmente em 1,45 μm , 1,95 μm , 2,7 μm , nas chamadas bandas de absorção, com picos em 1,6 e 2,2 μm (LIU, 2006; RICHARDS, 1986). Portanto, à medida que o conteúdo de água na planta diminui, ocorre um aumento da reflectância do infravermelho médio (NOVO, 2008). Estudando a beterraba infectada pelo fungo *Rhizoctonia solani*, os autores Webb e Calderón (2015) compararam o infravermelho próximo e o infravermelho médio para identificar e diferenciar a ação do fungo, já os autores Reynolds et al. (2012) utilizaram medidas hiperespectral e associaram as parcelas saudáveis ao aumento do infravermelho médio e à diminuição do infravermelho próximo.

2.2.2 Índices de vegetação

Os índices de vegetação são medidas radiométricas adimensionais, que auxiliam na extração e na modelagem de parâmetros biofísicos da vegetação, a partir de dados de sensoriamento remoto multiespectral e têm sido amplamente empregados no monitoramento de culturas agrícolas (ASHOURLOO, MOBASHERI; HUETTE, 2014; BREDEMEIER et al., 2013; HILLNHUNTTER et al., 2011; JUNGES; FONTANA, 2011) pelo fato de permitirem a análise da distribuição espacial das áreas cultivadas, e por mapearem as diferenças de vigor das plantas, além de melhorarem o direcionamento das amostragens e observações de campo, promovendo, assim, uma avaliação mais eficaz do potencial de produção (MACHADO, 2003).

O índice de vegetação da Diferença Normalizada, NDVI, proposto por Rouse et al. (1973), trata da relação entre as reflectâncias

na região do infravermelho próximo e na região visível do vermelho. A razão entre essas regiões pode ser explicada pela intensa absorção da clorofila na região do vermelho (0,63 – 0,69 μ m) e por uma intensa energia refletida na região do infravermelho próximo (0,76 – 0,90 μ m), causada pela estrutura celular da folha (LOURENÇO; LANDIM, 2004).

Autores utilizaram o NDVI para verificar efeito da ferrugem asiática na soja (HIKISHIMA et al., 2010); na análise da cana-de-açúcar infectada pela larva do besouro (MARTINS; GALO, 2015); em plantas de algodoeiro atacados pelo percevejo castanho (MOTOMIYA et al., 2012) e observaram que o índice apresentou boa resposta às características da doença.

O Índice de Vegetação da Diferença Normalizada do Verde, GNDVI, proposto por Gitelson et al. (1996), é derivado da combinação das bandas do infravermelho próximo e do verde. E em relação ao NDVI, apresenta um alcance dinâmico mais amplo e, em média, é, pelo menos, cinco vezes mais sensível à concentração da clorofila *a*. E, por isso, tem sido utilizado para detectar a concentração de clorofila, a fim de medir a taxa de fotossíntese e, dessa forma, monitorar o estresse da planta. Autores que analisaram culturas de feijão infectadas pelo fungo *Sclerotinia sclerotiorum* (BOECHAT et al., 2014) e trigo infestado pelo *Diuraphis noxia* (Mordviko) verificaram que o GNDVI captou melhor a variação da gravidade da doença (MIRIK et al., 2012).

O Índice da Diferença Normalizada da Água, NDWI, visa a medir o teor da umidade na vegetação e é derivado da combinação das bandas do infravermelho próximo e do infravermelho médio, que removem variações induzidas pela estrutura interna foliar e pelo teor

da matéria seca da folha, melhorando a precisão na recuperação do teor de água da vegetação (CECCATO et al., 2001).

As informações sobre o conteúdo de umidade interno da vegetação são de grande utilidade na agricultura, na floresta e na hidrologia (GALVÃO et al., 2005). Hardisky et al. (1983) e Gao (1996) observaram que o NDWI, baseado nas bandas do infravermelho próximo e do infravermelho médio do TM/Landsat, era altamente correlacionado com o conteúdo de água do dossel vegetal e acompanhava melhor as mudanças na biomassa e nos estresses de umidade das plantas do que o índice NDVI. Jackson et al. (2004) observaram que o NDVI saturava, enquanto que o NDWI continuava a registrar mudanças no conteúdo de água de áreas plantadas com o milho e com a soja (JENSEN, 2009).

2.3 Geoestatística

A Geoestatística teve seu início com os estudos de George Matheron na França, no final da década de 50. Fundamentada na teoria das variáveis regionalizadas, Matheron (1963) formalizou-a a partir dos estudos práticos de Daniel G. Krige (1951), em uma reserva de ouro na África do Sul, onde concluiu que somente a informação dada pela variância era insuficiente para estudar o fenômeno, sendo necessário levar em consideração a distância entre as observações e a dependência que existia entre elas (BICALHO, 2008).

Os métodos geoestatísticos oferecem apoio à análise e ao monitoramento de componentes dos sistemas ambientais e agrícolas, com o intuito de caracterizar as causas e os efeitos de variações do ambiente, do hospedeiro e do patógeno, como também o resultado da interação entre a doença e o estado nutricional do hospedeiro (ALVES

et al., 2012). Dessa maneira, Zucoloto, Lima e Coelho (2009) analisaram a probabilidade de ocorrência do Mal-do-Panamá (*Fusarium oxysporum f. sp. cubense*) em bananeira Prata-Anã e diagnosticaram, pelo mapeamento da doença, as áreas que apresentaram maior severidade, o que auxiliou nas medidas preventivas e no isolamento de áreas afetadas. Além desses autores, Amado et al. (2009), Zucoloto et al. (2011), Uchôa et al. (2011), Freitas et al. (2015) analisaram a variabilidade espacial de atributos do solo e a influência nas culturas de feijão, do milho e na produção de bananeira variedade Prata-Anã.

A geoestatística proporciona um modelo que permite a análise da variabilidade em qualquer espaço \mathfrak{R}^d , não importa sua natureza, se somente espacial, se somente temporal, ou espaçotemporal (SILVA; RIBEIRO JÚNIOR, 2007).

O tempo e o espaço não são diretamente comparáveis, já que as unidades das coordenadas dos dois processos apresentam grandezas diferentes. Fisicamente, há uma diferença entre as dimensões espaciais e temporais e os modelos geoestatísticos precisam considerá-las. Diante disso, na estrutura da dependência espaçotemporal dos dados, a função de covariância é a ferramenta mais utilizada para a modelagem por possuir estrutura uniforme em todos os domínios e, nesse caso, a função espacial obedece ao mesmo modelo da função temporal, sendo este baseado em métricas espaçotemporais em que a distância permite usar modelos válidos no contexto meramente espacial (MONTERO; FERNÁNDEZ-AVILÉS; MATEU, 2015).

As funções de covariância separáveis, no caso deste trabalho, a Duplamente Exponencial, não levam em conta a parametrização entre o espaço e o tempo, já a função de covariância não separável, modelo

de Gneiting (2002), propõe um modelo em que a obtenção de funções de covariâncias válidas não separáveis é feita de combinações de funções completamente monótonas, com funções positivas e uma derivada completamente monótona. O espaço e o tempo são dimensões que não se comparam diretamente, pois no espaço não há ideia de ordenação (passado, presente e futuro), o que é bem definida no tempo, mas há conceitos de isotropia e anisotropia, os quais não fazem sentido para o tempo.

Em estudos nos quais os autores analisam os processos dinâmicos que ocorrem tanto no tempo quanto no espaço, como as taxas de monóxido de carbono (CO) em Madri (MONTERO; FERNÁNDEZ-AVILÉS, 2015), dados de precipitação, por hora, na Suíça (HUSER; DAVISON, 2013), os modelos de covariância espaçotemporal captaram melhor os fenômenos.

A krigagem é um interpolador exato, utilizado pela Geoestatística, que visa a ponderar os vizinhos do ponto a ser estimado, fornecendo estimativas pontuais não viciadas e de variância mínima (MONTERO; FERNÁNDEZ-AVILÉS; MATEU, 2015). E os tipos mais usuais são a ordinária, a universal e a co-krigagem.

A krigagem ordinária é um método de estimação utilizado quando não conhecemos o valor da média espacial (BICALHO, 2008). É um método robusto que não apresenta viés e linear, pelo fato das suas estimativas serem combinações lineares dos dados (GOOVAERTS, 1997; ISAAKS; SRIVASTAVA, 1989).

Vários trabalhos empregaram o método de krigagem ordinária, como o de Uchôa et al. (2011) em que analisaram a variabilidade espacial da Sigatoka Negra com a fertilidade do solo e verificaram uma forte dependência espacial da severidade da doença. Por meio de

mapas de krigagem ordinária, observaram um padrão agregado e a relação negativa da severidade da doença com teores de potássio e positiva com teores de enxofre no solo. Áreas com níveis mais altos de K apresentaram menor severidade e, em áreas com maiores teores de enxofre, foi verificada elevada severidade da doença. Alves et al. (2011), pelos mapas de krigagem ordinária, visualizaram a intensidade da infestação de broca do café (*Hypothenemus hampei*) e do bicho mineiro do café (*Leucoptera coffeella*) em folhas, para diferentes períodos e caracterização de seus padrões espaciais no campo. Freitas et al. (2015), observaram pelo mapa de krigagem que havia taxa de infecção mais baixa de Sigatoka amarela em áreas com maiores teores cálcio (Ca) e magnésio (Mg) no solo.

A variância de krigagem é a variância do erro de estimação. Portanto, a variância de krigagem indica o quão precisas são as previsões e predições realizadas (MONTERO; FERNÁNDEZ-AVILÉS, 2015).

REFERÊNCIAS

ALVES, M. C.; et al. Geostatistical analysis of the spatial variation of the berry borer and leaf miner in a coffee agroecosystem. **Precision Agriculture**, v. 12, p. 18-31, 2011.

ALVES, M. C., et al., Geoestatística na proteção de plantas: geoinformação do pesquisador ao produtor. In: Simpósio avanços na otimização do uso de defensivos agrícolas no manejo fitossanitário, 12., 2012, Lavras. **Anais...** Lavras, UFLA, 2012. 1 CD-ROM.

AMADO, T. J. C., et al., Atributos químicos e físicos de latossolos e sua relação com os rendimentos de milho e feijão irrigados. **Revista Brasileira de Ciência do Solo**, v. 33, p. 831-843, 2009.

ASHOURLOO, D.; MOBASHERI, M. R.; HUETTE, A. Evaluating the Effect of Different Wheat Rust Disease Symptoms on Vegetation Indices Using Hyperspectral Measurements, **Remote Sensing**, v. 6, p. 5107-5123, 2014.

BASSOI, L. H.; et al. **Agricultura de precisão resultados de um novo olhar**. Brasília: Embrapa Instrumentação, 2014, 596 p.

BICALHO, B. C. **Modelos Espaço-Temporais: Estudos de Casos**. 2008. 174. Dissertação (Mestrado em Estatística) – Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

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

BORGES, A. L.; SOUZA, L. S. Exigências edafoclimáticas. In: _____. **O cultivo da bananeira**. Cruz das Almas: EMBRAPA, 2004. p. 15-23.

BREDEMEIER, C.; VARIANI, C.; ROSA, A. T. Estimativa do potencial produtivo em trigo utilizando sensor óptico ativo para adubação nitrogenada em taxa variável. **Ciência Rural**, v. 43, n. 7, p. 1147-1154, 2013.

CASTELAN, F., et al., Relation between the severity of Sigatoka disease and banana quality characterized by pomological traits and fruit green life. **Crop Protection**, v. 50, p. 61–65, 2013.

- CECCATO, P. et al., Detecting vegetation leaf water content using reflectance in the optical domain. **Remote Sensing e Environment**, v.77, p. 22-33, 2001.
- CORDEIRO, Z. J.M; MATOS, A. P. Expressão da Resistência de Variedades de Banana à Sigatoka-Amarela. **Fitopatologia brasileira**, Brasília, v. 30, n. 5, p.534, set-out, 2005.
- CORDEIRO, Z. J. M.; MATOS, A. P.; KIMATI, H. Doenças da bananeira. In: KIMATI, H. et al. (Ed). **Manual de Fitopatologia: doenças das plantas cultivadas**. 5. ed. São Paulo: Agronômica Ceres, 2005, v. 2, p. 99-117.
- CRISÓSTOMO, L. A.; NAUMOV, A. Adubando para alta produtividade e qualidade: fruteiras tropicais do Brasil. Fortaleza: **Embrapa Agroindústria Tropical**, 2009. 238p.
- DALLEMAND, J.F.; TARDIN, A.T.; BATISTA, G.T. Sensoriamento remoto e agricultura. **Ciência Hoje**, v. 8, p. 44-51, 1988.
- DHAU, I., et al. Testing the capability of spectral resolution of the new multispectral sensors on detecting the severity of grey leaf spot disease in maize crop. **Geocarto International** ISSN: 1010-6049 (Print) 1752-0762 (Online), 2017. doi: 10.1080/10106049.2017.1343391
- EPAGRI - Recomendações técnicas para o cultivo em Santa Catarina - Disponível em: <http://www.epagri.sc.gov.br/?page_id=1349>. Acesso em: 15 de nov 2016.
- EPIPHANIO, J.C.N.; LEONARDI, L.; FORMAGGIO, A.R. Relações entre parâmetros culturais e resposta espectral de cafezais. **Pesquisa Agropecuária Brasileira**, Brasília, v. 29, n. 3, p. 379-386, 1994.
- FIORAVANÇO, J. C. Mercado mundial de banana: produção comércio e participação brasileira. **Informações econômicas** v. 33, p. 15-27, 2003.
- FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. São Paulo: Oficina de Textos, 2.ed. 2007. 101p.
- FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS STATISTICS DIVISION. **Production/Crops**. Disponível em: <<http://faostat3.fao.org/browse/Q/QC/E>>. Acesso em: 04 set. 2017.

FREITAS, A. S. et al. Spatial distribution of Yellow Sigatoka Leaf Spot correlated with soil fertility and plant nutrition. **Precision Agriculture**, Oxford, v. 17, n. 1, p. 93-107, 2015.

FREITAS, A. S. Processo infeccioso de *Pseudocercospora musae* e severidade da Sigatoka amarela da bananeira em função do silício, potássio e cálcio em solução nutritiva. 2016. 101p. Dissertação (Mestrado em Fitopatologia) Universidade Federal de Lavras/MG, 2016.

GALVÃO, L. S., FORMAGGIO, A. R.; TISOT, D. A. Discrimination of Sugarcane Varieties in Southeastern Brasil with EO-1 Hyperion Data. **Remote Sensing of Environment**, v. 94, p. 523-534, 2005.

GAO, B. NDWI- a normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, p. 257-266, 1996.

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

GOOVAERTS, P. (1997) Geostatistics for natural resources evaluation: Oxford University Press, New York, 483p.

HARDISKY, M.A., KLEMAS, V., and SMART, R.M., The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. **Photogrammetric Engineering and Remote Sensing** vol. 49, n. 1, p. 77-83, 1983.

HIKISHIMA, M. et al. Quantificação de danos e relações entre severidade, medidas de reflectância e produtividade no patossistema ferrugem asiática de soja. **Tropical Plant Pathology**, v. 35, n. 2, p. 096-103, 2010.

HILLNHUNTER, C. et al., Remote sensing to detect plant stress induced by *Heterodera schachtii* and *Rhizoctonia solani* in sugar beet fields. **Field Crops Research**, v. 122, p. 70-77, 2011.

HUSER, R.; DAVISON, A. C. Space-time modeling of extreme events. **Journal of the Royal Statistical Society: Series B (Statistical Methodology)** v.74, p. 439-461, 2013.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA.
Produção agrícola municipal. Disponível em:

<<http://www.sidra.ibge.gov.br/>>. Acesso em: 27 ago. 2017.

ISAAKS, H. E.; SRIVASTAVA, R. M. A. Introduction to applied geostatistics. Oxford: Oxford University Press. 1989. 560p.

JACKSON, T. J. et al. Vegetal Water Content Mapping using Landsat Data derived Normalized Difference Water Index for Corn and Soybeans. **Remote Sensing of Environment**, v. 92, p.475 – 482, 2004.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**, tradução José Carlos Neve Epiphanyo (coordenador)... [et al] – São José dos Campos, SP: Parêntese, 2009, 589p.

JUNGES, A. H.; FONTANA, D. C. Modelo agrometeorológico-espectral de estimativa de rendimento de grãos de trigo no Rio Grande do Sul. **Revista Ceres**. v. 58, p. 695-700, 2011.

KIMATI, H., et al., (Ed.) **Manual de fitopatologia**. São Paulo: Agronômica Ceres, 1997. p. 113-136.

KRIGE, D. G. A statistical approach to some basic mine valuation problems on the Witwatersrand. **Journal of the Chemical, Metallurgical and Mining Society of South Africa**, v. 52, n. 6, p. 119–139, 1951.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. Campo Grande: Ed. UNIDERP, 2006, 908p.

LOURENÇO, R.W.; LANDIM, P.M.B. Estudo da variabilidade do “Índice de vegetação por diferença normalizada/NDVI” utilizando krigagem indicativa. **Holos environment**, v. 4, n. 1, p.38-55, 2004.

LUKINA, E.V. et al. **Effect of row spacing, N rate and growth stage on spectral radiance in winter wheat**. OSU Soil Fertility Research Highlights. Oklahoma State University, Department of Plant and Soil Sciences. p. 251-258, 1997.

MACHADO, H. M. Determinação da biomassa de cana-de-açúcar considerando a variação espacial de dados espectrais do satélite LANDSAT 7 – ETM+. **Dissertação** (Mestrado em Engenharia

Agrícola) – Faculdade de Engenharia Agrícola. Universidade Estadual de Campinas, Campinas. 2003.

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

MATHERON, G. Principles of geostatistics. **Econ. Geol.**, v. 58, p.1246-1266, 1963.

MIRIK, M. et al. Spectral vegetation indices selected for quantifying Russian wheat aphid (*Diuraphis noxia*) feeding damage in wheat (*Triticum aestivum* L.). **Precision Agriculture**, v.13, p. 501-516, 2012.

MONTERO, J.M.; FERNÁNDEZ-AVILÉS, G. The role of visualisation in the choice of stationary non-separable space-time covariance functions: na application to air pollution data. **International Journal of Geographical Information Science**. v. 29, n.10, p. 1887-1909, 2015.

MONTERO, J. M.; FERNÁNDEZ-AVILÉS, G.; MATEU, J. **Spatial and Spatio-Temporal Geostatistical Modeling and Kriging**. Spain, Wiley, 1 ed., 2015. 400p.

MORAN, M.S., INOUE, Y., BARNES, E.M. Opportunities and limitations for imagebased remote sensing in precision crop management. **Remote Sensing of Environment**, v. 61, p. 319–346, 1997.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Viçosa: UFV. 3.ed., 2007. 320p.

MOTOMIYA, A. V. A. et al. Mapeamento do índice de vegetação da diferença normalizada em lavoura de algodão. **Pesquisa Agropecuária Tropical**, v. 42, n. 1, p. 112-118, 2012.

NAUE, C. R. et al. Sensoriamento remoto como ferramenta aos estudos de doenças de plantas agrícolas: uma revisão. **Revista Brasileira de Geografia Física**, 03, 190-195. 2010.

NOBEL, P.S. **Physicochemical and environmental plant physiology**. London: Academic Press, 1999. 474p.

NOVO, E. M. L. M. **Sensoriamento Remoto: princípios e aplicações.** 3 ed. São Paulo: Edgard Blücher, 2008.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação.** São José dos Campos: Ed. A. Silva Vieira. 2007. 128p.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação.** 2010. ed. São José dos Campos: Parêntese, 2010. 128 p.

POZZA, E. A.; POZZA, A. A. A. Relação entre nutrição e as doenças de plantas: implicações práticas. In: simpósio avanços na otimização do uso de defensivos agrícolas no manejo fitossanitário, 12., 2012, Lavras. **Anais...** Lavras: UFLA, 2012. 1 CD-ROM

REYNOLDS et al. Remote Sensing for Assessing Rhizoctonia Crown and Root Rot Severity in Sugar Beet. **Plant Disease**, vol. 96, n. 4. p. 497-505, 2012.

RICHARDS, J.A. **Remote sensing digital image analysis: an introduction.** Berlin: Springer-Verlag, 1986. 281p.

ROSA, R. Geotecnologias na geografia aplicada. **Revista do Departamento de Geografia**, v.16, p.81-90, 2005.

ROUSE, J. W. et al. **Monitoring vegetation systems in the Great Plains with ERTS. In: Earth Resources Technology Satellite-1 Symposium, 3**, 1973, Washington, DC. Proceedings... Washington, DC: NASA, p. 309-317, 1973.

SEELAN, S. K.; et al. Remote sensing applications for precision agriculture: A learning community approach. **Remote Sensing of Environment**, v. 88, n.1/2, p.157-169, 2003.

SENA JÚNIOR, D. G. et al. Discriminação entre estágios nutricionais na cultura do trigo com técnicas de visão artificial e medidor portátil de clorofila. **Eng. Agríc.**, v. 28, n.1, p.187-195, 2008.

SILVA, A. S.; JÚNIOR, P. J. R.; ELMATZOGLOU, I. Modelagem Geoestatística utilizando a família de gneiting de funções de covariância espaço-temporais. **Rev. Mat. Estat.**, v. 25, n. 1, p. 65–83, 2007.

SILVA, J. T. A.; SILVA, I. P.; PEREIRA, R. D. Adubação fosfatada em mudas de bananeira 'Prata anã (AAB), cultivadas em dois Latossolos. **Revista Ceres**, v. 58, n. 2, p. 238-242, 2011.

SILVA, S. O.; FLORES, J. C. O.; NETO, F. P. L. Avaliação de cultivares e híbridos de bananeira em quatro ciclos de produção, **Pesquisa Agropecuária Brasileira**, v. 37, n. 11, p. 1567–1574, 2002.

TOLLENAAR, D. The control of Sigatoka (Banana Leaf Spot Disease) by mist blowing with Banacobre-Snadoz. **Netherlands Journal of Agricultural Sciences**, Wageningen, v. 3, n. 1, p. 70-83, 1995.

UCHÔA, C. N. Modelagem Geoestatística da Sigatoka-negra e sua relação com a fertilidade do solo. **Bioscience Journal**, Uberlândia, v.27, n. 3, p. 357-362, 2011.

VENTURA, J. A.; HINS, R. H. Controle das doenças da bananeira. In: ZAMBOLIM, L.; VALE, F. X. R.; MONTERIO, A. J. A.; COSTA, H. Controle de doenças de plantas fruteiras, v. 2, p. 839-938, 2002.

WEBB, K. M.; CALDERÓN, F. J. Mid-Infrared (MIR) and Near-Infrared (NIR) Detection of *Rhizoctonia solani* AG-2-2 IIIB on Barley-Based Artificial Inoculum. **Applied Spectroscopy**, v. 69, n. 10, p. 1129-1136, 2015.

YAMAMOTO, J. K.; LANDIM, P. M. B.. **Geoestatística: conceitos e aplicações**. São Paulo: Oficina de Textos, 2013.

ZUCOLOTO, M.; LIMA, J. S. S.; COELHO, R. I. Uso da Geoestatística na probabilidade de ocorrência do Mal-do-Panamá em bananeira. **Revista Fac. Nal. Agr.**, v. 62, n.1, p. 4793-4796, 2009.

ZUCOLOTO, M. et al. Variabilidade espacial das frações granulométricas e da produção de bananeira 'Prata-Anã'. **IDESIA** (Chile) v. 29, n. 2, p. 47-52, 2011.

SEGUNDA PARTE - ARTIGOS

ARTIGO 1

Caracterização Espectral e Temporal da Sigatoka amarela na cultura da bananeira

Artigo submetido ou em processo de submissão

Julia Dal Poggetto Rodrigues¹ - Marcelo de Carvalho Alves¹ -
Aurivan Soares de Freitas² - Edson Ampélio Pozza³

¹Engineering Departament, Federal University of Lavras, PO BOX 3037, CEP 37200-000, Lavras, MG, Brazil.

²University of Vale do Rio Verde, Av. Castelo Branco, 82, Chácara das Rosas, CEP 37410-000, Três Corações, MG, Brazil.

³Plant Pathology Departament, Federal University of Lavras, PO BOX 3037, CEP 37200-000, Lavras, MG, Brazil.

Autor para correspondência: Marcelo de Carvalho Alves
marcelocarvalhoalves@gmail.com

Preparado em concordância com as normas do periódico

“Precision Agriculture”

(Versão preliminar – em processo de submissão)

Resumo

A Sigatoka amarela em estágios avançados causa manchas necróticas, modificando a estrutura interna da folha da bananeira. Sendo assim, objetivou-se analisar a resposta espectral da bananeira (*Musa* spp.) infectada por *Pseudocercospora musae* (*Mycosphaerella musicola*), agente etiológico da Sigatoka amarela da bananeira. Foram utilizadas imagens Landsat 7, do sensor Enhanced Thematic Mapper Plus (ETM+), referentes à área do bananal, localizado no município de Lavras/MG e compararam-se dois métodos de correção atmosférica: método Second Simulation of Sattelite Signal in the Solar Spectrum (6S) e o Dark Object Substraction 1 (DOS1), para a análise da assinatura espectral da vegetação e para o cálculo do Índice de Vegetação da Diferença Normalizada (NDVI), Índice de Vegetação da Diferença Normalizada no Verde (GNDVI) e Índice da Diferença Normalizada da Água (NDWI). Constataram-se altos valores de reflectância nas duas últimas imagens, datadas em 15/09/2012 e 01/10/2012, no comprimento de onda do infravermelho médio para as regiões caracterizadas com alto valor de índice de infecção da doença e os índices de vegetação, principalmente o NDWI relacionado à umidade da vegetação, que apresentou baixos valores nessas duas últimas datas e correlação negativa com a doença para a penúltima avaliação da infecção (27/09/2012).

Palavras-chave: Sensoriamento remoto. *Musa* spp.. *Mycosphaerella musicola*. Landsat 7. Índices de vegetação.

Introdução

A banana (*Musa* spp.) está entre as frutas mais consumidas no mundo, constituindo importante papel social e econômico na geração de emprego e renda (Fioravanço, 2003). Dentre as doenças que afetam a bananeira, a Sigatoka amarela, cujo agente etiológico é *Mycosphaerella musicola* Leach na fase sexuada e o *Pseudocercospora musae* Zimm na fase assexuada, está entre as mais destrutivas (Cordeiro e Matos, 2005). Atualmente, a doença ocorre em todas as áreas produtoras de banana do Brasil, reduzindo a área fotossintetizante da planta e, conseqüentemente, a produção e a qualidade do fruto (Castelan et al., 2013).

O manejo da Sigatoka amarela envolve, basicamente, a aplicação periódica de fungicidas e o uso de variedades resistentes (Cordeiro e Matos, 2005). Como um método alternativo, a nutrição mineral e equilibrada contribui na formação de barreiras de resistência (Pozza e Pozza, 2012). Além da produção, estudos realizados recentemente com a bananeira têm evidenciado que a nutrição equilibrada também aumenta a resistência às doenças (Freitas et al., 2015a, Freitas et al., 2015b, Freitas et al., 2017).

Para a análise do ataque de doenças em plantas, têm sido utilizadas ferramentas do sensoriamento remoto. De acordo com Epiphanyo et al. (1994) e Dallemand et al. (1988), essa técnica apresenta um grande potencial no levantamento de dados, no monitoramento de doenças no planejamento agrícola. Pode servir para a detecção e o monitoramento de plantas infectadas e/ou áreas atacadas por fitopatógenos de forma rápida e eficiente, contribuindo na redução de riscos de poluição por agrotóxicos e para uma melhor produtividade de grãos (Naue et al., 2010).

Os índices de vegetação são muito empregados no monitoramento e na quantificação das condições de distribuição espacial da vegetação (Gitelson et al., 2001). O Índice de Vegetação da Diferença Normalizada (NDVI) foi utilizado para verificar o efeito da ferrugem asiática na soja (Hikishima et al., 2010), na análise da cana-de-açúcar infectada pela larva do besouro (Martins e Galo, 2015) e em plantas de algodoeiro atacadas pelo percevejo castanho (Motomiya et al., 2012). O Índice de Vegetação da Diferença Normalizada no Verde (GNDVI) foi utilizado em trabalhos, que também analisaram o NDVI, em feijoeiro infectado pelo fungo *Sclerotinia sclerotiorum* (Boechat et al., 2014) e em plantações de trigo, atacadas pelo *Diuraphis noxia* (Mirik et al., 2012).

Além dos índices de vegetação, a análise da assinatura espectral auxilia na discriminação de doenças fúngicas por ser influenciada pelos pigmentos presentes na folha, tais como a clorofila *a* e *b*, carotenos, xantofila e antocianinas, que provocam a absorção da radiação eletromagnética ou influenciam nos processos fisiológicos associados ao desenvolvimento do vegetal (Abdel-Rahman e Ahmed, 2008).

Na literatura, são encontrados trabalhos que analisaram o comportamento espectral de vegetações agredidas por fitopatógenos como, por exemplo, eucaliptos atacados por *Phaeophleospora eucalypti* e *Mycosphaerella* spp (Lippert et al., 2009; Lippert et al., 2015) e também cultivares agrícolas como algodão, por percevejo castanho, *Scaptocoris castânea* (Motomiya et al., 2012); trigo, por *Diuraphis noxia* (Mirik et al., 2012); feijão, por *Sclerotinia sclerotiorum* (Boechat et al., 2014); cana de açúcar, pela larva do besouro *Migdolus fryanus* (Martins e Galo, 2015); beterraba, pelo

fungo *Rhizoctonia solani* (Webb; Calderón, 2015; Reynolds et al., 2012); o milho, pela mancha foliar (*Cercospora zea-maydis*) (Dhau et al., 2017); o café, pela *Hemileia vastarix* (Chemura et al., 2016) e também análises referentes à eficiência de fungicidas no controle da ferrugem asiática da soja *Glycine max* L. (Silva et al., 2009).

Esse trabalho apresenta relevância não só na análise de uma cultura tão importante socioeconomicamente, mas também por fornecer ao produtor uma alternativa mais rentável comparada à análise de campo e à utilização de espectroradiômetros, visto que há um vasto acervo de imagens orbitais disponíveis gratuitamente. Diante disso, o presente trabalho teve como objetivo analisar a resposta espectral da bananeira sob diferentes condições da Sigatoka amarela *P. musae* (*M. musicola*) da bananeira e compreender a modificação que a doença ocasiona nas folhas.

Material e Métodos

Obtenção de dados *in situ*

Realizou-se um experimento em um bananal da variedade Prata-Anã, em que foi avaliada a severidade da Sigatoka amarela nas folhas de bananeira, *in situ*, conforme descrito em detalhes por Freitas et al. (2015a).

Área de estudo

A área de estudo está localizada no sítio Vale dos Ventos, município de Lavras/MG (Fig. 1). A região, em que o sítio está inserido, apresenta um relevo ondulado e de acordo com a classificação de Köppen, o clima da região é do tipo Cwb (tropical de

altitude), apresenta chuvas durante todo o ano, sendo mais concentradas no verão (Fig. 2).

A área do bananal compreendeu 1,2 ha, cujo cultivar plantado foi a Prata-Anã, com espaçamento de 4m x 3m entre as plantas. A área foi escolhida por apresentar alta severidade da Sigatoka amarela e por não possuir qualquer medida de controle, o que permitiu o estudo do comportamento da doença em condições naturais de infecção.

O experimento foi conduzido no período de maio a outubro de 2012 e foram georreferenciados 27 pontos espaçados com malha regular de 18 x 18m (324 m²), utilizando GPS modelo Trimble 4600 LS (Fig. 1).

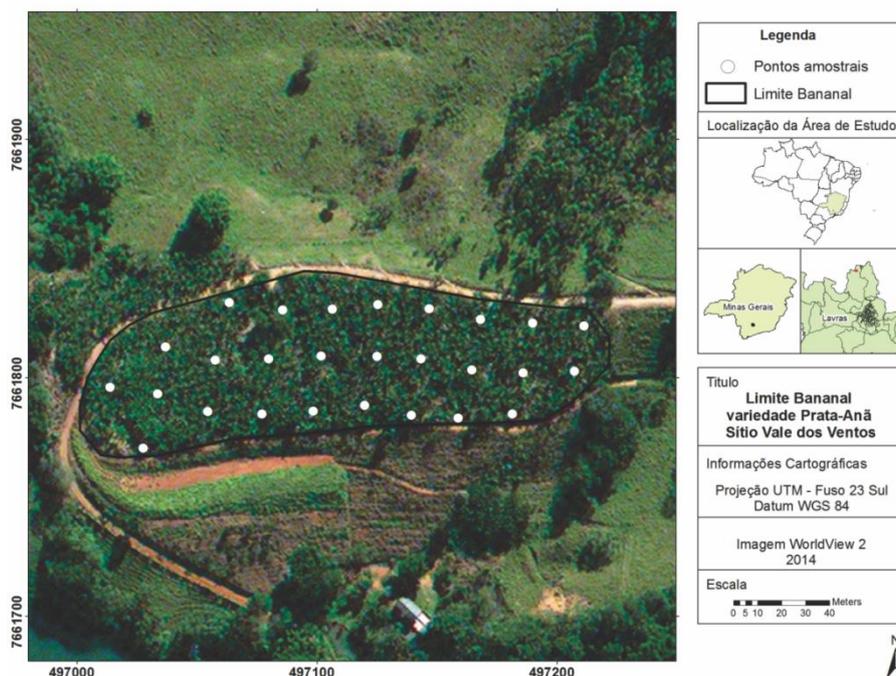


Fig. 1 Localização do bananal variedade Prata-anã, Sítio Vale dos Ventos, município de Lavras/MG, onde foram coletados os dados *in situ*, em malha amostral com 27 pontos para avaliar a severidade da Sigatoka amarela.

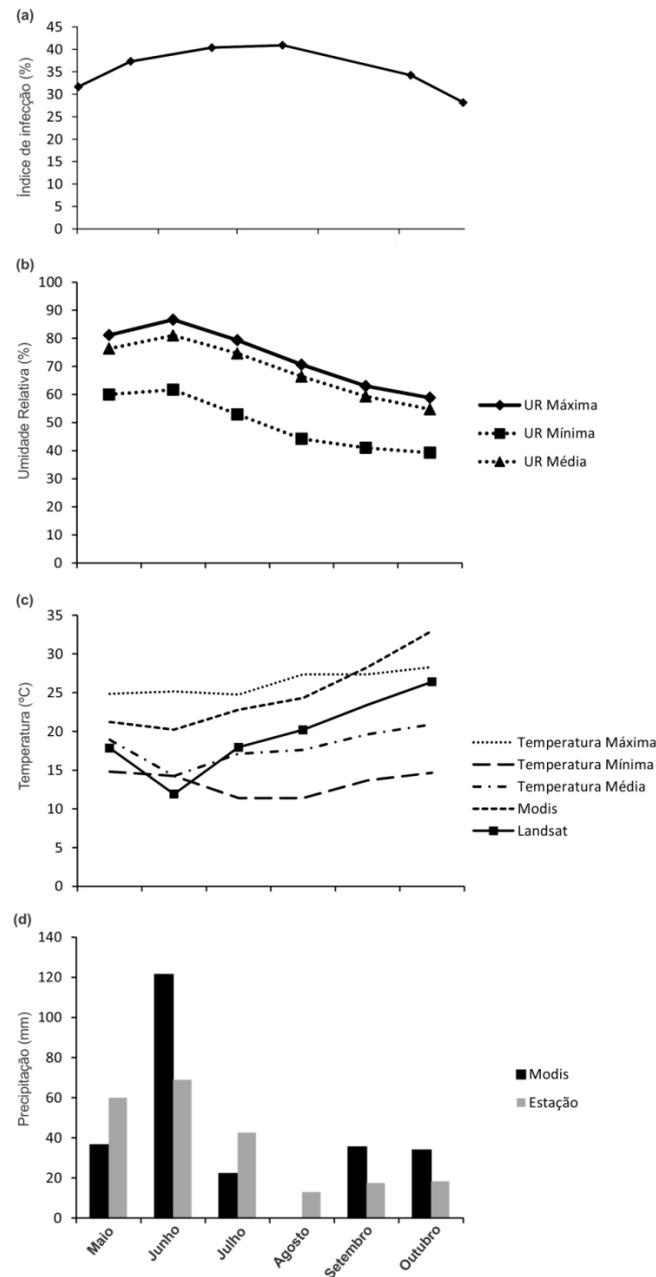


Fig. 2 Curva de progresso das taxas médias de infecção da Sigatoka Amarela (a), valores máximo, médio e mínimo de umidade relativa (b), valores de temperatura máxima, média e mínima, obtidos pelo sensor MODIS e pelo sensor ETM+ do satélite Landsat 7 (c), valores precipitação obtidos pela estação e pelo produto MODIS/NASA, através do site Series View/INPE, no Sítio Vale dos Ventos, município de Lavras/MG, entre os meses de maio e outubro de 2012.

Avaliação da doença

A severidade da Sigatoka amarela foi avaliada uma vez por mês, sempre na mesma planta, selecionada em cada ponto georreferenciado com o auxílio de escala diagramática proposta por Stover (1972) e modificada por Gauhl (1994). A severidade da doença foi transformada em índice de infecção (ii) de acordo com a equação abaixo:

$$\text{Índice de infecção} = [\sum nb/(N)T] * 100$$

Em que:

n é o número de folhas em cada nível da escala de Stover modificada por Gauhl,

b o grau da escala,

N o número de graus empregados na escala e

T o número total de folhas avaliadas.

Obtenção de dados orbitais

Foram obtidas as imagens do satélite Landsat 7, sensor ETM+, Collection 1 Level 1 e da Higher-Level (Surface Reflectance), que estão disponíveis na página do USGS (United States Geological Survey) e que são referentes à área de estudo, datadas em 10/05/2012, 27/06/2012, 29/07/2012, 15/09/2012 e 01/10/2012. A seleção das datas das imagens foi realizada de acordo com a proximidade das datas das avaliações da severidade da doença.

As imagens adquiridas possuem 8 bandas multiespectrais, resolução temporal de 16 dias, resolução espacial de 30 metros para as bandas do visível, Infravermelho próximo e médio, 60m para a banda

termal e 15m para a pancromática e resolução radiométrica de 8 bits (2^8) (Tabela 1).

Tabela 1 Resoluções espectral, espacial, temporal e radiométrica do sensor ETM+, do satélite Landsat 7.

Banda	Resolução				
	Espectral	Espacial	Temporal	Radiométrica	
Visível	1	450 – 515	30 m	16 dias	8 bits
	2	520 – 605	30 m	16 dias	8 bits
	3	630 – 690	30 m	16 dias	8 bits
NIR	4	750 – 900	30 m	16 dias	8 bits
SWIR 1	5	1550 – 1750	30 m	16 dias	8 bits
Termal	6	10400 - 12500	60 m	16 dias	8 bits
SWIR 2	7	2090 – 2350	30 m	16 dias	8 bits
Pancromática	8	520 – 900	15 m	16 dias	8 bits

Processamento das imagens

As imagens orbitais foram reprojetaadas para a projeção Universal Transversa de Mercator (UTM), no Datum WGS 84, zona 23 sul, com o intuito de adequá-las à base de dados de campo.

A correção atmosférica foi realizada nas imagens obtidas da Collection 1 Level 1, pelo método DOS1 (Dark Object Subtraction) desenvolvido por Chavez (1989), em que é feito uma estimativa da interferência atmosférica em cada banda espectral, seguida pelos cálculos para a transformação do número digital em valores de radiância e, então, para valores de reflectância (Gurtler et al., 2005).

Já as imagens adquiridas do Higher-Level (Surface Reflectance) foram disponibilizadas com a interferência atmosférica corrigida pelo método 6S (Second Simulation of Sattelite Signal in the Solar Spectrum), o qual é fundamentado no modelo de transferência radiativa (Vermont et al., 1997) e foi desenvolvido para simular a radiância que chega nos sensores em bandas dentro do espectro solar,

entre 0,25µm a 4,0µm, com o objetivo de determinar as características dos sensores (Antunes et al., 2012).

Para verificar o resultado de uma correção atmosférica, é necessário observar as curvas de assinatura espectral de alvos conhecidos presentes na imagem, pois o comportamento espectral é resultado do conjunto dos valores sucessivos da reflectância do objeto ao longo do espectro eletromagnético (Antunes et al., 2012).

Cálculo da Temperatura de Brilho

A temperatura de brilho foi calculada conforme a equação:

$$T_B = \frac{K_1}{\ln[K_1 / L_\lambda] + 1}$$

Em que T_B é a temperatura de brilho; K_1 , constante de calibração para a banda termal 1; K_2 , constante de calibração para a banda termal 2; L_λ , a radiância espectral na abertura do sensor.

Medição da Assinatura Espectral

Posteriormente, com a geração das bandas (1, 2, 3, 4, 5 e 7) em um único raster foram selecionados os pixels com base nas áreas em que apresentavam alto, médio e baixo índices de infecção da Sigatoka amarela (Tabela 2 Fig. 3) de acordo com Freitas et al. (2015), para a medição da assinatura espectral da área.

A ausência da imagem referente ao mês de agosto é devido ao fato de a área de estudo ter sido coberta pelo ruído da imagem. Devido a esse fato, a análise da assinatura espectral referente ao mês de agosto não foi realizada.

Tabela 2 Valores baixo, médio e alto do índice de infecção (ii) da Sigatoka amarela das datas 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 09/08/2012 (ii4), 27/09/2012 (ii5) e 17/10/2012 (ii6) encontrados no Sítio Vale dos Ventos, município de Lavras/MG.

Índice de infecção	Baixo	Médio	Alto	Landsat 7 ETM +
23/05/2012 (ii1)	≤ 5	5 a 33	≥ 33	10/05/2012
12/06/2012 (ii2)	≤ 5	5 a 33	≥ 33	27/06/2012
13/07/2012 (ii3)	≤ 5	5 a 33	≥ 33	29/07/2012
09/08/2012 (ii4)	≤ 5	5 a 33	≥ 33	
27/09/2012 (ii5)	≤ 5	5 a 33	≥ 33	15/09/2012
17/10/2012 (ii6)	≤ 5	5 a 33	≥ 33	01/10/2012

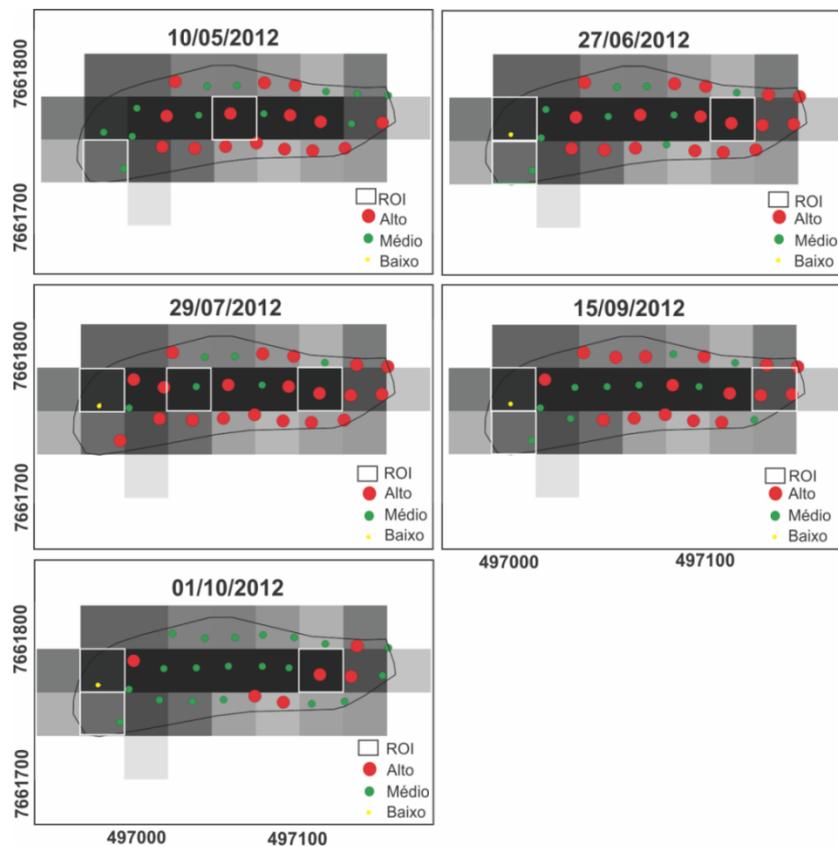


Fig. 3 Metodologia empregada na seleção do pixel das imagens da Collection 1 Level 1 e da Collection Higher Level, datadas em 10/05/2012, 27/06/2012, 29/07/2012, 15/09/2012 e 01/10/2012, para captar a assinatura espectral da vegetação com base nos valores baixo (≤ 5), médio (5 a 33) e alto (≥ 33) de severidade da Sigatoka amarela encontrados no do bananal da variedade Prata-anã, Sítio Vale dos Ventos, município de Lavras/MG.

Cálculo dos índices de vegetação

Utilizando uma ferramenta matemática, foram calculados os índices relacionados à biomassa e à área foliar, NDVI, nutriente da planta, GNDVI, umidade da vegetação e o NDWI (Tabela 3), já que a Sigatoka amarela modifica a estrutura interna da folha, além de causar a necrose da planta em estágios mais avançados da doença.

Tabela 3 Índices de vegetação: Índice da Diferença Normalizada (NDVI), Índice de Vegetação da Diferença Normalizada no Verde (GNDVI) e Índice da Diferença Normalizada da Água (NDWI) relacionados à biomassa, aos nutrientes da planta e à umidade da vegetação.

Índice	Equação	Relação a:	Referência
Índice de Vegetação da Diferença Normalizada	$NDVI = (\rho_{NIR} - \rho_R) / (\rho_{NIR} + \rho_R)$	Biomassa/ área foliar	Rouse et al. (1974)
Índice de Vegetação da Diferença Normalizada no Verde	$GNDVI = (\rho_{NIR} - \rho_G) / (\rho_{NIR} + \rho_G)$	Nutriente da planta	Gitelson et al. (1996)
Índice de Diferença Normalizada da Água	$NDWI = (\rho_{NIR} - \rho_{SWIR}) / (\rho_{NIR} + \rho_{SWIR})$	Umidade da vegetação	Gao (1996)

NIR, Infravermelho próximo; R, Vermelho; G, Verde; SWIR, Infravermelho médio, ρ Reflectância.

Extração dos valores

Assim que todos os índices foram calculados, foram extraídos os valores do píxel para cada ponto amostrado nas imagens datadas em 10/05/2012, 27/06/2012, 29/07/2012, 15/09/2012 e 01/10/2012, referentes à Collection 1 Level 1 e à Higher-Level (Surface Reflectance).

Estatística descritiva

Foram feitas análises de correlação com os dados dos índices de infecção e os valores extraídos para testar se o coeficiente de correlação Pearson (r) foi significativamente diferente de zero, ao nível de significância de 5%.

Resultados e Discussão

A composição colorida RGB falsa-cor (Fig. 6) da área de estudo manteve um padrão na tonalidade entre os pixels centrais das imagens. Essa composição permite uma melhor percepção do estado da vegetação. De acordo com Novo (1992), ao selecionar a combinação de canais e filtros, deve-se conhecer o comportamento espectral do alvo de interesse, o que facilita a extração de informações, a partir dos dados de sensoriamento remoto, como a análise espectral da vegetação.

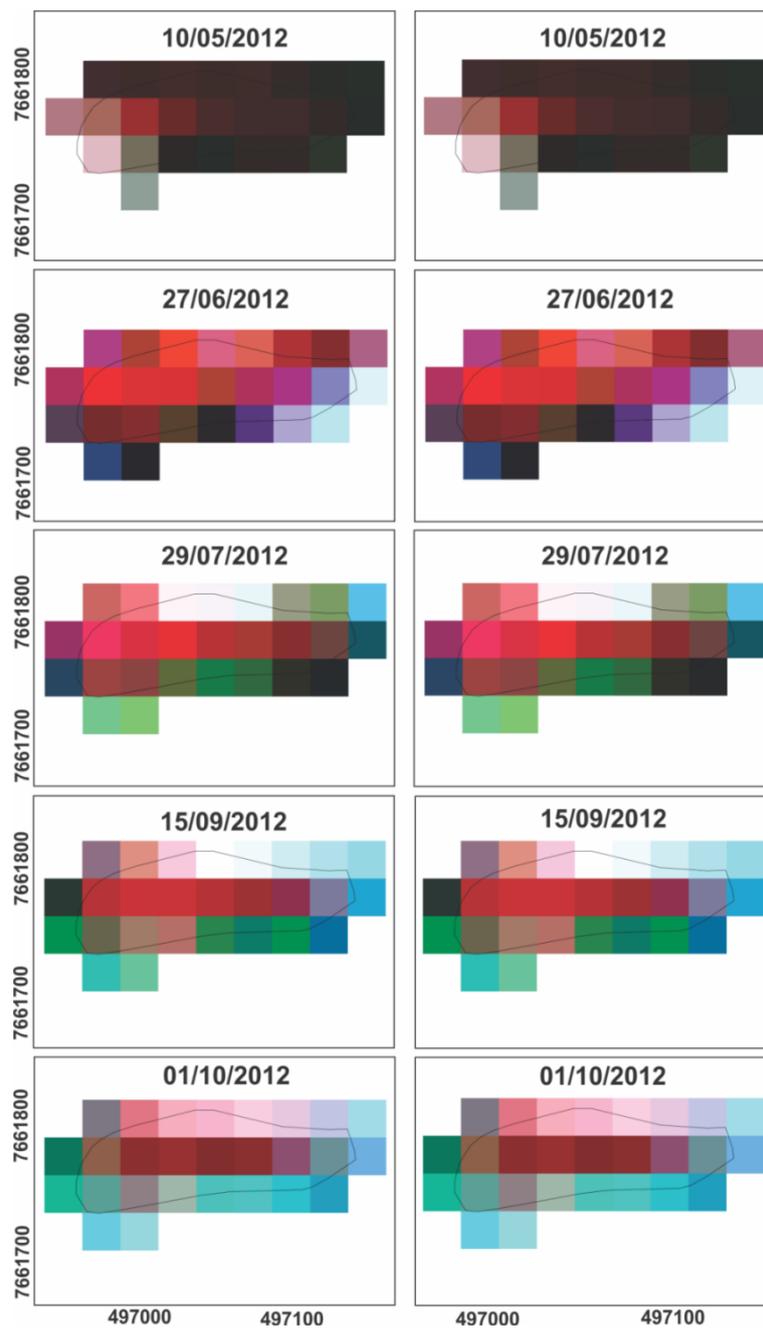


Fig. 4 Composição colorida RGB falsa cor (bandas 4, 3 e 2) referente às datas 10/05/2012, 27/06/2012, 29/07/2012, 15/09/2012 e 01/10/2012, das imagens do satélite Landsat 7, sensor ETM+, Collection Level 1, correção atmosférica DOS1 (esquerda) e Collection 1 Higher Level, correção atmosférica 6S (direita) referente ao bananal variedade Prata-anã, localizado no Sítio Vale dos Ventos, município de Lavras/MG.

A seleção da amostragem do pixel levou em conta o alcance espacial da Sigatoka amarela na área de estudo, que manteve uma média de 30 m ao longo dos seis meses, em que foi avaliada a doença, conforme descrito em Freitas et al. (2015a). Dessa maneira, o tamanho do pixel da imagem Landsat 7, sensor ETM+, que é de 30m x 30m, apresentou um suporte geográfico para a caracterização da doença na área de estudo.

Na análise da assinatura espectral da imagem datada em 10/05/2012 (Fig. 5 e 6), não foi realizada a medição da assinatura espectral referente à região com baixo valor de severidade da doença por não apresentar esse valor na classificação utilizada. O valor de média severidade apresentou reflectância mais alta para ambos os métodos de correção atmosférica.

Pela análise da assinatura espectral da imagem, datada em 29/07/2012 (Fig. 5 e 6), observou-se que os valores de reflectância na região do infravermelho próximo foram maiores nas áreas, em que o índice de infecção da Sigatoka amarela foi mais baixo do que em relação à área, a qual apresentava alto índice de infecção da doença, tanto para as imagens com correção atmosférica do DOS 1, quanto para as imagens corrigidas pelo método 6S.

Na cultura do feijão Boechat et al. (2014), observaram a redução da reflectância na região do infravermelho próximo em plantas infectadas por *Sclerotinia sclerotiorum*, fungo causador do mofo-branco. Assim, como Mirik et al. (2012) na cultura do trigo, que constataram a menor reflectância na região do infravermelho próximo no trigo infestado pelo *Diuraphis noxia* (Mordviko), devido à redução da área foliar verde por rolamento e aumento da formação de lesões.

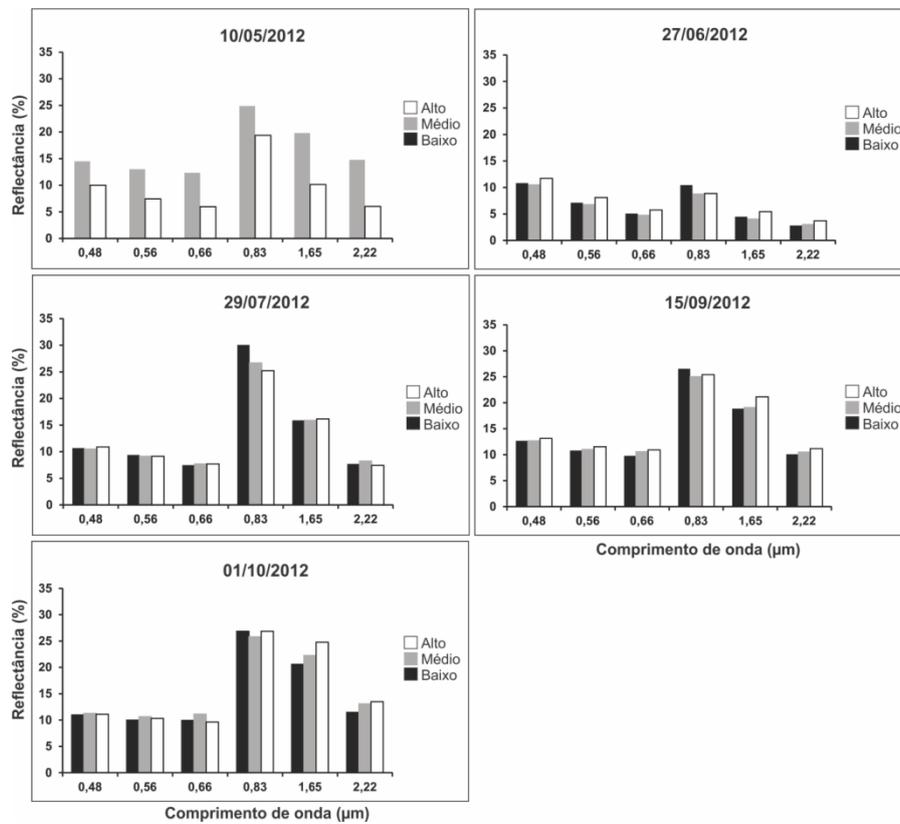


Fig. 5 Assinatura espectral de plantas de bananeira com baixo e alto valor do índice de infecção (ii) da Sigatoka amarela referente às datas 10/05/2012, 27/06/2012, 29/07/2012, 15/09/2012 e 01/10/2012 das imagens do satélite Landsat 7, sensor ETM+, Collection 1 level 1, correção atmosférica DOS 1, com base nos dados de índice de infecção (ii) da Sigatoka amarela, datados em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 27/09/2012 (ii5) e 17/10/2012 (ii6), localizada no bananal variedade Prata-anã, Sítio Vale dos Ventos, município de Lavras/MG.

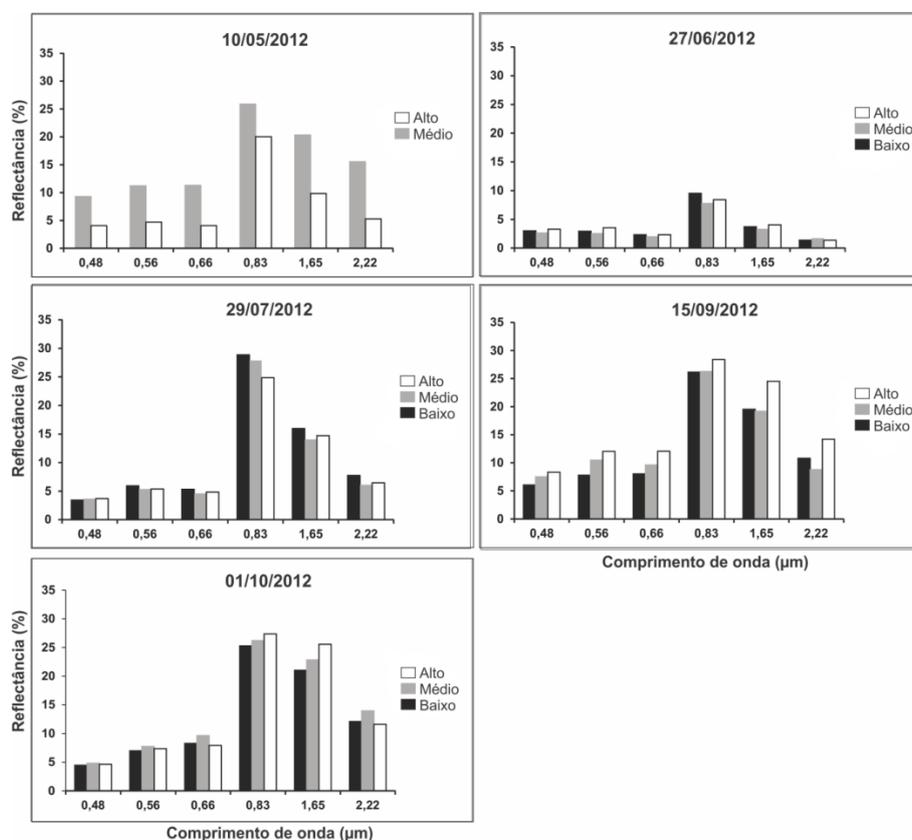


Fig. 6 Assinatura espectral de plantas de bananeira com baixo e alto valor do índice de infecção (ii) da Sigatoka amarela referente às datas 10/05/2012, 27/06/2012, 29/07/2012, 15/09/2012 e 01/10/2012 das imagens do satélite Landsat 7, sensor ETM+, Collection Higher Level (Surface Reflectance), correção atmosférica 6s, com base nos dados do índice de infecção (ii) da Sigatoka amarela, datados em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 27/09/2012 (ii5) e 17/10/2012 (ii6), localizada no bananal variedade Prata-anã, Sítio Vale dos Ventos, município de Lavras/MG.

Nas assinaturas espectrais das datas 15/09/2012 e 01/10/2012, com correção atmosférica 6S (Fig. 6), constatou-se que, nas áreas com baixo, médio e alto índice da Sigatoka amarela, houve uma variação na região do visível (0,52 a 0,60 μm), onde ocorreu a absorção da clorofila. A área, que apresentou baixo índice, foi a que absorveu mais, principalmente, a da imagem datada em 01/10/2012, que apresentou uma maior variação na área, classificada como de alto

índice de infecção, pois nas bandas que absorveram a energia, ela refletiu, o que é um indicador de ausência de clorofila e de estresse da vegetação.

Na cultura do milho, Dhau et al. (2017) utilizaram imagens de alta e média resolução para analisar a classificação do milho em moderado e severamente infectado pela mancha foliar (*Cercospora zea-maydis*) e nas imagens dos satélites WorldView 2 e Quickbird, a banda do vermelho discriminou bem as categorias da infecção.

Em relação à região do infravermelho próximo, as assinaturas das imagens datadas em 15/09/2012 e 01/10/2012 (Fig. 5 e 6) apresentaram maiores valores de reflectância em regiões de alto índice de infecção (ii) da Sigatoka amarela. Lippert et al. (2015) analisaram folhas de *Eucalyptus globulus* atacadas em quatro diferentes níveis de severidade pelo fungo *Mycosphaerella* spp. em diferentes posições na copa da árvore, também notaram que as folhas mais atacadas pelo fungo apresentavam maiores valores de reflectância. Martins e Galo, (2015) ao caracterizarem espectralmente a cana-de-açúcar sadia e infectada por nematoides e pela larva do besouro *Migdolus fryanus*, observaram um aumento na região do infravermelho próximo, a partir da região de 800nm, na cana infectada pela larva do besouro. Os autores Motomiya et al. (2012) analisaram lavoura de algodão atacada por percevejo castanho, *Scaptocoris castanea*, e também observaram maior reflectância na região do visível e na região do infravermelho próximo, na lavoura que apresentava infestação da doença, em relação à lavoura sadia.

A região do infravermelho próximo é relacionada a estudos sobre o ataque de doenças fúngicas na soja. Silva et al. (2009) utilizaram um radiômetro portátil para comparar medidas de

reflectância na análise da eficiência de fungicidas no controle da ferrugem asiática da soja (*Glycine max* L.) e obtiveram correlação entre a região do infravermelho próximo com a produtividade e a severidade.

O comprimento de onda do infravermelho médio é caracterizado pela absorção de água e, nas assinaturas espectrais de 15/09/2012 e 01/10/2012 (Fig. 5 e 6), constatou-se que os valores de reflectância foram maiores para a região em que o índice de infecção era alto, o que sugeriu uma possível perda de água pela folha devido à ação do patógeno. Sendo assim, o fungo promoveu a degradação dos tecidos verdes, e, conseqüentemente, a dos pigmentos responsáveis pela fotossíntese, como a clorofila *a* e *b* (Rodríguez-Gaviria e Cayón, 2008). Dessa maneira, em decorrência da doença, modificou a estrutura interna da folha e acarretou a redução do tecido fotossintético, ocorrendo também a alteração do comportamento espectral da folha em diferentes regiões.

Em relação à assinatura espectral de 27/06/2012 e 29/07/2012, nas referidas datas, a temperatura (Fig. 2) apresentou valores médios menores que 21°C e que, de acordo com Cordeiro, Matos e Kimati (2016), temperaturas abaixo desse valor provocam considerável declínio na ocorrência da doença e na taxa de infecção. Nos meses de junho e julho, os valores de reflectância da região considerada de baixa severidade apresentaram maiores valores de reflectância no comprimento de onda do infravermelho médio (Fig. 5 e 6).

Na análise da beterraba atacada pelo fungo *Rhizoctonia solani*, os autores Webb e Calderón (2015) compararam o infravermelho próximo e o infravermelho médio para identificar e diferenciar a beterraba colonizada da não inoculada e concluíram que o

infravermelho médio se mostrou mais sensível para a diferenciação. Os autores Reynolds et al. (2012) utilizaram medidas hiperespectrais e associaram as parcelas saudáveis ao aumento do infravermelho médio e à diminuição do infravermelho próximo, enquanto as parcelas que apresentaram maior severidade foram associadas à reflectância do solo descoberto, visto que a raiz, nesse estágio, encontrou-se completamente podre e a folha, morta.

Índices de Vegetação

Em relação aos índices de vegetação calculados nas imagens corrigidas pelo método 6S, observou-se que para as cinco imagens processadas os valores de NDVI foram maiores no mês de maio e menores, no mês de setembro (Fig. 8). Na correlação do NDVI com o índice de infecção (ii) da Sigatoka amarela, o valor do índice da imagem, datada em 29/07/2012, apresentou correlação negativa ($r: -0,383$) com o índice de infecção avaliado em 27/09/2012 (Tabela 5).

Comparando os valores do NDVI em relação aos diferentes métodos de correção utilizados, DOS 1 e 6S (Fig. 7 e 8), observou-se que os valores do DOS1 ficaram muito inferiores em relação aos do 6S, uma vez que a imagem apresentou uma grande quantidade de nuvem. Pode-se dizer que o método 6S corrigiu o efeito sobre a imagem de maneira mais eficiente.

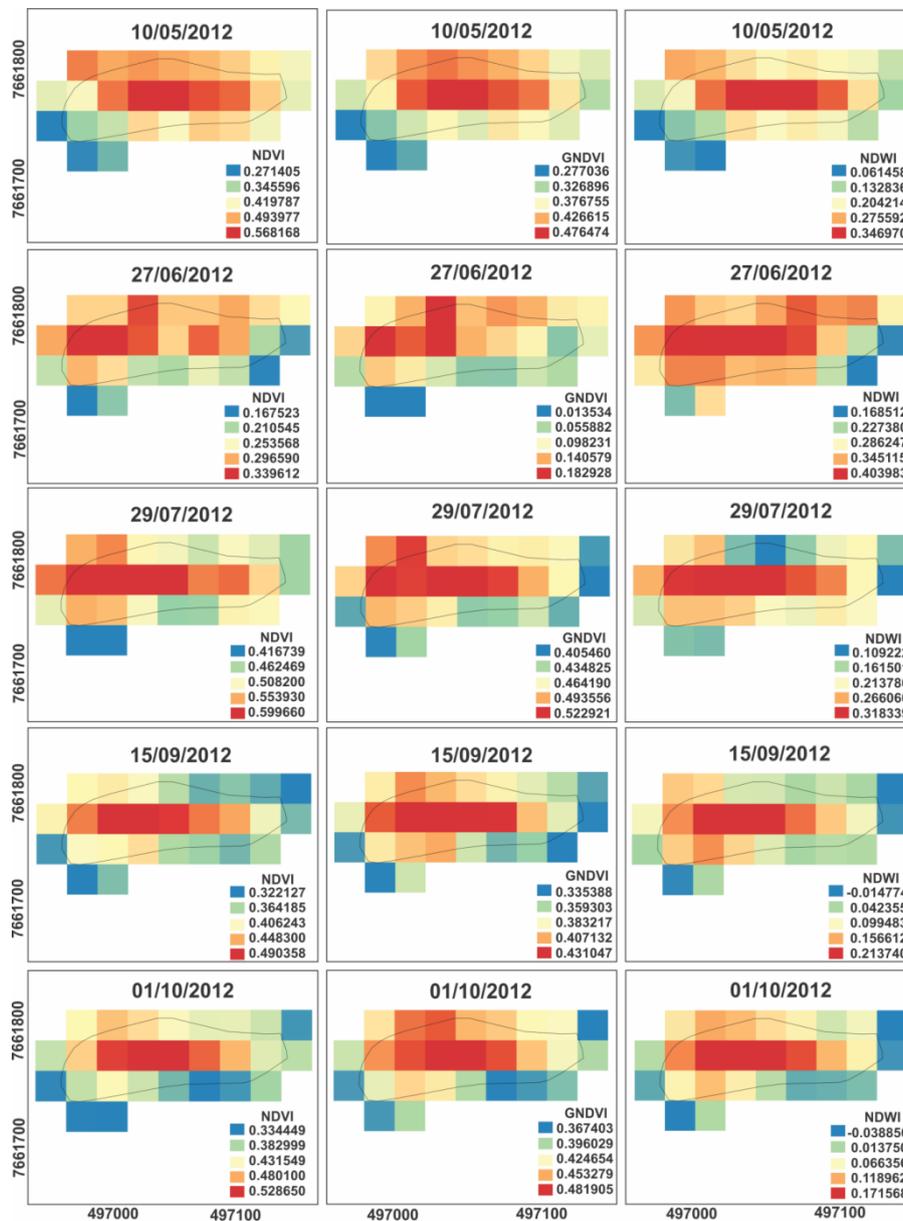


Fig. 7 Índice de Vegetação da Diferença Normalizada (NDVI) (esquerda), Índice de Vegetação da Diferença Normalizada do Verde (GNDVI) (centro) e Índice de Diferença Normalizada da Água (NDWI) (direita) para as datas 10/05/2012, 27/06/2012, 29/07/2012, 15/09/2012 e 01/10/2012, das imagens do satélite Landsat 7, sensor ETM+, Collection Level 1, com correção atmosférica DOS1.

Tabela 4 Correlação ao nível de significância de 5% entre o Índice de Vegetação da Diferença Normalizada (NDVI), Índice de Vegetação da Diferença Normalizada do Verde (GNDVI) e Índice de Diferença Normalizada da Água (NDWI) da imagem Landsat 7, sensor ETM+, Collection 1 Level 1 com correção atmosférica DOS1, datadas em 27/06/2012, 29/07/2012 e 15/09/2012 com os dados dos índices de infecção (ii) da Sigatoka amarela, avaliadas na Fazenda Vale dos Ventos, município de Lavras/MG, em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 09/08/2012 (ii4), 27/09/2012 (ii5) e 17/10/2012 (ii6).

DATA	ÍNDICE	ii1	ii2	ii3	ii4	ii5	ii6
27/06/2012	GNDVI						-0,415
27/06/2012	NDVI	-0,419			-0,386		
29/07/2012	NDVI					-0,384	
29/07/2012	NDWI					-0,388	
15/09/2012	GNDVI						-0,431
15/09/2012	NDWI					-,0384	

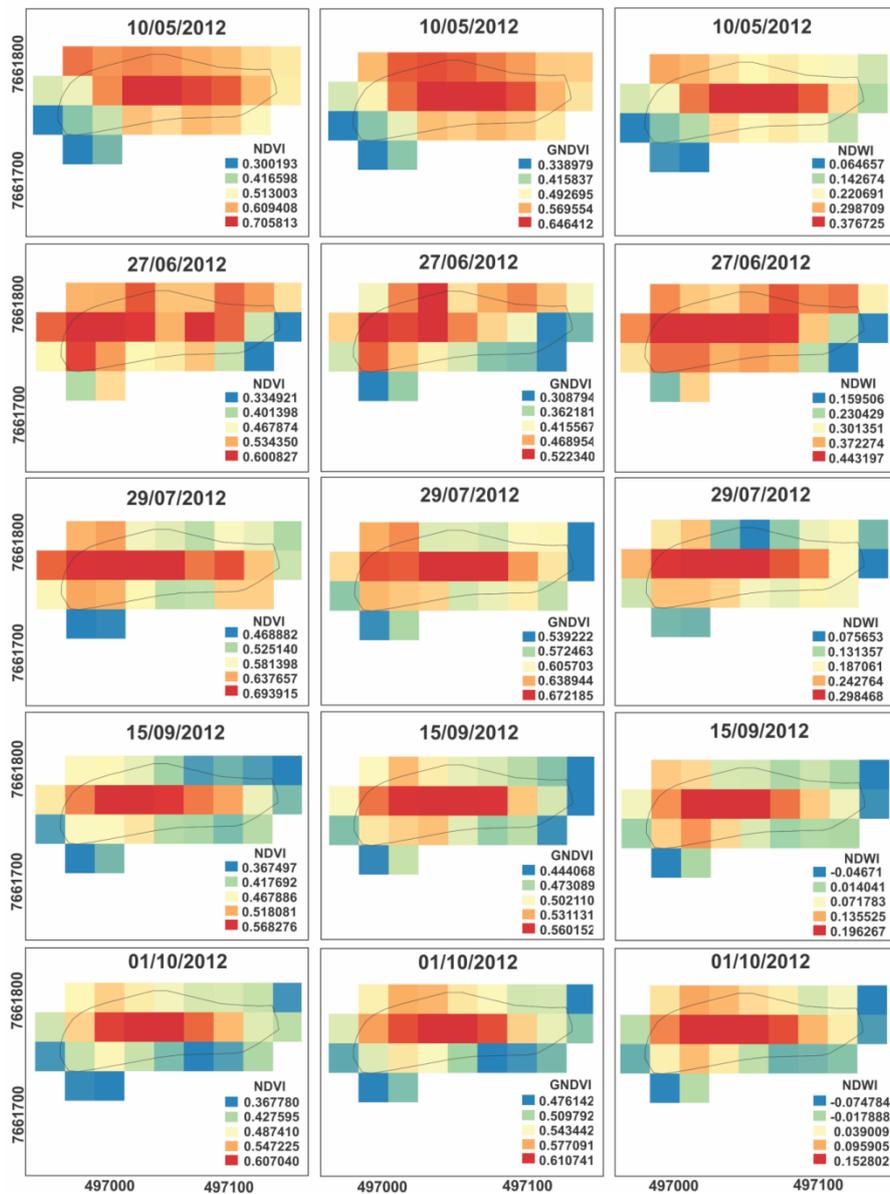


Fig. 8 Índice de vegetação da Diferença Normalizada (NDVI) (esquerda), Índice de Vegetação da Diferença Normalizada do Verde (GNDVI) (centro) e Índice de Diferença Normalizada da Água (NDWI) (direita) para as datas 10/05/2012, 27/06/2012, 29/07/2012, 15/09/2012 e 01/10/2012, das imagens do satélite Landsat 7, sensor ETM+, Collection Higher-Level (Surface Reflectance), com correção atmosférica 6S.

Tabela 5 Correlação ao nível de significância de 5% entre o Índice de Vegetação da Diferença Normalizada (NDVI), Índice de Vegetação da Diferença Normalizada do Verde (GNDVI) e Índice de Diferença Normalizada da Água (NDWI), da imagem Landsat 7, sensor ETM+, Higher-Level (Surface Reflectance) com correção atmosférica 6S, datadas em 27/06/2012, 29/07/2012 e 15/09/2012 com os dados de índice de infecção (ii) da Sigatoka amarela, avaliadas na Fazenda Vale dos Ventos, município de Lavras/MG, em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 09/08/2012 (ii4), 27/09/2012 (ii5) e 17/10/2012 (ii6).

DATA	ÍNDICE	ii1	ii2	ii3	ii4	ii5	ii6
27/06/2012	GNDVI		-0,401				-0,400
29/07/2012	NDVI					-0,383	
15/09/2012	NDWI					-0,384	
15/09/2012	GNDVI						-0,431

Os autores Hikishima et al. (2010) verificaram o efeito da ferrugem asiática da soja, causada pelo fungo *P. pachyrhizi*, em lavouras com e sem controle da doença e notaram que o NDVI foi o índice que apresentou diferença significativa entre os tratamentos, sendo a parcela sem o controle da doença aquela com o menor valor desse índice, o que indicou que a ferrugem reduziu a reflectância da área foliar sadia. Assim como Martins e Galo (2015) encontraram os menores valores de NDVI para a cana-de-açúcar infectada pela larva do besouro *Migdolus fryanus* que, além de apontar para o comprometimento da cultura ao ser infectada, indicou que, à medida que os valores de infecção são altos, os valores de NDVI tendem a cair.

Os autores Motomiya et al. (2012) obtiveram dados de reflectância dos componentes do NDVI, utilizando sensor ótico ativo sobre veículo aéreo não tripulado em plantas de algodoeiro, em duas lavouras com condições distintas, área normal e área com mancha. devido ao ataque do percevejo castanho, causado pelo fungo *Scaptocoris castânea* e notaram a variabilidade espacial do NDVI na

lavoura, que apresentava maior estresse fisiológico, devido ao ataque do fungo.

Em relação ao GNDVI, notaram-se valores maiores no mês de julho, os quais concentraram nos pixels da região central da área de estudo (Fig. 7). A correlação entre o GNDVI e o índice de infecção da Sigatoka amarela foi negativa ($r: -0,431$) (Tabela 5), ou seja, os valores de GNDVI aumentaram à medida que os valores de infecção diminuíram. Em relação aos valores do GNDVI na data 27/06/2012 (Fig. 8), os valores do índice em que a imagem foi corrigida pelo método 6S foram maiores em relação às imagens corrigidas pelo DOS1, assim como ocorreu com o índice NDVI.

Boechat et al. (2014) analisaram a resposta espectral de plantas de feijoeiro infectados por *Sclerotinia sclerotiorum*, fungo causador do mofo-branco e pela transformação dos dados em índices NDVI e GNDVI. Também verificaram a correlação entre a severidade da doença e o NDVI em estágio de enchimento de grãos e maturação, quando a ocorrência da doença passou a ser detectada pelos índices de vegetação e a severidade do mofo-branco. Já Mirik et al. (2012) analisaram o trigo infestado pelo inseto *Diuraphis noxia* (Mordviko) e constataram que os valores dos índices NDVI e GNDVI foram reduzidos nas áreas infectadas e que o GNDVI captou melhor a variação da gravidade da doença.

Os valores do índice NDWI (Fig. 7 e 8) foram menores nas últimas datas, 15/09/2012 e 01/10/2012. A correlação entre o NDWI e o índice de infecção avaliado em 27/09/2012 (ii5) foi negativa ($r: -0,384$), ou seja, quanto maior a infecção menor o valor do NDWI (Tabela 5).

Os baixos valores do NDWI e a correlação negativa com o índice de infecção da Sigatoka amarela podem ser explicados pelo fato de que, ao longo do tempo, o agente etiológico *P. musae* causou necrose da folha, ou seja, a folha perdeu água nos últimos estágios da doença e, como o NDWI é sensível à mudança de teor de umidade no dossel da vegetação (Gao, 1996), captou essa característica da doença e, assim, apresentou valores menores nas últimas avaliações.

As correlações dos índices de vegetação com os valores do índice de infecção da Sigatoka amarela (Tabelas 4 e 5) apresentaram valores muito próximos, tanto para um método de correção atmosférica quanto para o outro. Os índices de vegetação na época da seca não apresentaram correlação, porque o enfolhamento ou número de folhas caiu vertiginosamente, devido ao déficit hídrico, além do mais a doença necrosou as poucas folhas remanescentes. Sendo assim, não se teve vegetação ou houve redução drástica na área verde.

A ocorrência da Sigatoka amarela foi influenciada não só pelas variáveis climáticas, mas também pela nutrição mineral, pelas condições do solo e do relevo. Freitas et al. (2015a) encontraram baixos valores de índice de infecção da Sigatoka amarela nas áreas em que havia maior teor de cálcio (Ca) e de Magnésio (Mg) no solo e de enxofre (S) na folha da bananeira. O Ca e o Mg são constituintes da lamela e tornam a bananeira mais resistente à ação de enzimas produzidas pelos fungos patogênicos (Huber e Jones, 2013).

Em relação às condições do solo, Freitas et al. (2015a) observaram altos valores de índice de infecção da Sigatoka amarela em áreas com maior teor de areia e menor teor de silte e matéria orgânica, visto que o solo nessas condições apresentam menor

capacidade de retenção de água e de disponibilização de nutrientes as raízes das plantas (Silva, 1999).

Conclusão

A assinatura espectral da bananeira pôde ser utilizada na caracterização de diferentes níveis de infecção da Sigatoka amarela, principalmente ao analisar o comprimento de onda do infravermelho próximo e do infravermelho médio, visto que a necrose causada pela doença na folha acarretou em perda de água da planta, alterando a fotossíntese e a reflectância da cultura.

Entre os índices de vegetação, o NDVI e o GNDVI apresentaram diferença entre os métodos de correção atmosférica, principalmente na imagem do mês de junho, que apresentou um maior número de nuvens. Em relação à doença, o índice NDWI demonstrou melhores resultados.

Referências

- Abdel-Rahman, E. M. & Ahmed, F. B. (2008). The application of remote sensing techniques to sugarcane (*Saccharum* spp. Hybrid) production: a review of the literature. *International Journal of Remote Sensing*, 29 (13), 3753-3767.
- Antunes, M. A. H., Debiase, P., Costa, A. R., Gleriani, J. M. (2012). Correção atmosférica de imagens ALOS/AVNIR-2 utilizando o modelo 6S. *Revista Brasileira de Cartografia*, 64 (4), 531-539.
- Boechat, L. T. Pinto, F. A. C., Paula Jr., T. J., Queiroz, D. M., Teixeira, H. (2014). Detecção do mofo-branco no feijoeiro, utilizando características espectrais. *Revista Ceres*, 61 (6), 907-915. doi: 10.1590/0034-737X201461060004
- Castelan, F.P., Abadie, C., Hubert, O., Chilin-Charles, Y., De Bellaire, L. L., & Chillet, M. (2013). Relation between the severity of Sigatoka disease and banana quality characterized by pomological traits and fruit green life. *Crop Protection*, 50 (1), 61–65.
- Chavez Júnior., P. S. (1989). Radiometric calibration of Landsat Thematic Mapper multispectral images. *Photogrammetric Engineering and Remote Sensing*, Bethesda, 55, 1285-1294.
- Chemura, A., Mutanga, O., Dube, T. (2016) Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolution. *Precision Agriculture*, doi: 10.1007/s11119-016-9495-0.
- Coppin, P. R. & Bauer, M. E. (1994). Processing of multitemporal Landsat TM imagery to optimize extraction of forest cover change features. *IEEE Transactions on Geoscience and Remote Sensing*, 32 (4), 918– 927.
- Cordeiro, Z. J.M; Matos, A. P. (2005). *Expressão da Resistência de Variedades de Banana à Sigatoka-Amarela*. Fitopatologia brasileira, Brasília, 30, (5), 532-534.
- Dallemand, J.F., Tardin, A.T., Batista, G.T. (1988). Sensoriamento remoto e agricultura. *Ciência Hoje*, 8, 44-51.
- Dhau, I., Adam, E., Mutanga, O., Ayisi, K., Abdel-Rahman, E. M., Odindi, J., Masocha, M. (2017). Testing the capability of spectral resolution of the new multispectral sensors on detecting the severity of grey leaf spot disease in maize crop. *Geocarto International* ISSN: 1010-6049 (Print) 1752-0762 (Online), doi: 10.1080/10106049.2017.1343391
- Freitas, A. S., Pozza, E. A., Alves, M. C., Coelho, G., Rocha, H. S., Pozza, A. A. A. (2015a). Spatial distribution of Yellow Sigatoka Leaf Spot correlated with soil fertility and plant nutrition. *Precision Agriculture*, 17, (1), 93-107.

- Freitas, A. S., Pozza, E. A., Pozza, A. A. A., Oliveira, M. G. F., Silva, H. R., Rocha, H. S., Galvão, L. R. (2015b). Impact of nutritional deficiency on Yellow Sigatoka of banana. *Australian Plant Pathology Society*, doi: 10.1007/s13313-015-0371-6
- Freitas, A. S., Pozza, E. A., Pozza, A. A. A., Soares, M. G. O., Silva, H. R., Pérez, C. D. P. (2017). Interaction between potassium (K) and calcium (Ca) on the severity of Yellow Sigatoka in banana plants. *African Journal of Agricultural Research*, 12 (16), 1353-1361. doi: 10.5897/AJAR2017.12279
- Epiphanyo, J. C. N., Leonardí, L., Formaggio, A.R. (1994). Relações entre parâmetros culturais e resposta espectral de cafezais. *Pesquisa Agropecuária Brasileira*, 29 (3), 379-386.
- Florenzano, T. G. (2002). *Imagens de satélites para estudos ambientais*. São Paulo: Oficina de Textos.
- Fung, T. (1990). An assessment of TM imagery for land-cover change detection. *IEEE Transactions in Geoscience and Remote Sensing*. 28 (4), 681– 684.
- Gao, B. (1996). NDWI- a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58, 257-266.
- Gauhl, F. (1994). Epidemiology and Ecology of Black Sigatoka (*Mycosphaerella fijiensis* Morelet) on Plantain and banana (*Musa* spp) in Costa Rica, Central América. Montpellier: INIBAP.
- Gilabert, M. A., González-Piqueras, J., García-Haro, F. J., Meliá, J. (2002) A generalized soil-adjusted vegetation index. *Remote Sensing of Environment*, 82, 303–310.
- 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 Environment*, 58, 289-298.
- Gitelson, A. A., Merzlyak, M. N., Chivkunova, O. B. (2001). Optical properties and nondestructive estimation of anthocyanin content in plant leaves. *Photochemistry and Photobiology*, 74 (1), 38-45.
- Gürtler, S., Epiphanyo, J. C. N., Luiz, A. J. B., Formaggio, A. R. (2005). Planilha eletrônica para o cálculo da reflectância em imagens TM e ETM+ Landsat. *Revista Brasileira de Cartografia*, 57, 162-167.
- Hikishima, M. Canteri, M. G., Godoy, C. V., Koga, L. J., Silva, A. J. (2010). Quantificação de danos e relações entre severidade, medidas de reflectância e produtividade no patossistema ferrugem asiática de soja. *Tropical Plant Pathology*, 35 (2), 096-103.
- Huber, D. M. & Jones, J. B. (2013). The role of magnesium in plant disease. *Plant and Soil*, 368 (1/2), 73-85.

- Lippert, D. B., Benedetti, A. P. P., Pereira, R. S., Muniz, M. F. B. (2009). Espectrorradiometria de folhas de *Eucalyptus camaldulensis* Dehnh. atacadas por *Phaeophleospora eucalypti*. In: XIV Simpósio Brasileiro de Sensoriamento Remoto. Natal, Brasil, p. 2793- 2799.
- Lippert, D. B., Benedetti, A. P. P., Muniz, M. F. B., Pereira, R. S., Biernaski Jr., C. A., Finkenauer, E., Berra, E. F. (2015). Comportamento espectral de folhas de *Eucalyptus globulus* (Labill.) atacadas por *Mycosphaerella* spp. nas regiões do visível e do infravermelho próximo do espectro eletromagnético. *Ciência Florestal* [online], 25 (1), 211-219.
- Martins, G. D. & Galo, M. L. B. T. (2015). Caracterização espectral da cana-de-açúcar infectada por nematoides e *mioglyphus fryanus* por espectrorradiometria de campo. *Boletim de Ciências Geodésicas* [Online version], doi: 10.1590/S1982-21702015000400046
- Mirik, M., Ansley, R. J., Michels Jr., Elliot, N. C. (2012). Spectral vegetation indices selected for quantifying Russian wheat aphid (*Diuraphis noxia*) feeding damage in wheat (*Triticum aestivum* L.). *Precision Agriculture*, doi: 10.1007/s11119-012-9264-7
- 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.
- Naue, C. R., Marques, M. W., Lima, N. B., Galvêncio, J. D. (2010). Sensoriamento remoto como ferramenta aos estudos de doenças de plantas agrícolas: uma revisão. *Revista Brasileira de Geografia Física*, 03, 190-195.
- Novo, E. M. L. de M. (1992). *Sensoriamento Remoto - Princípios e Aplicações*. São Paulo, SP: Editora Edgard Blücher.
- Pozza, E. A. & Pozza, A. A. A. (2012). Relação entre nutrição e as doenças de plantas: implicações práticas. In: simpósio avanços na otimização do uso de defensivos agrícolas no manejo fitossanitário, 12., 2012, Lavras. Anais... Lavras: UFLA, 2012. 1 CD-ROM.
- Reynolds, G. J., MacRae, I. V., Laguette, S. (2012). Remote Sensing for Assessing Rhizoctonia Crown and Root Rot Severity in Sugar Beet. *Plant Disease*, doi: 10.1094/ PDIS-11-10-0831
- Rodríguez-Gaviria, A. A. & Cayón, G. (2008). Efecto de *mycosphaerella fijiensis* sobre la fisiologia de la hoja de banana. *Agronomía Colombiana*, 26 (2), 256–265.

- Silva, A. J. da., Canteri, M. G., Santiago, D. C., Hikishima, M., Silva, A. L. (2009). A reflectância na estimativa do efeito de fungicidas no controle da ferrugem asiática da soja. *Summa Phytopathologica*, 35 (1), 53-56.
- Silva, J. T. A., Borges, A. L., & Malburg, J. L. (1999). Solos, adubação e nutrição da bananeira. *Informe agropecuário*. 20 (196), 21–36.
- Stover, R. H. (1972). *Banana, plantain and Abaca disease*. Kew: Commonwealth Mycological Institute.
- Vermote, E. F. (1997). Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: an overview. *IEEE Transactions on Geoscience and Remote Sensing*. 35 (3), 675-686.
- USGS – United States Geological Service. Landsat4-7 Surface Reflectance (LEDAPS) Product. Version 7.8. Junho, 2017. Disponível em: <https://landsat.usgs.gov/sites/default/files/documents/ledaps_product_guide.pdf>. Acesso em: 01. jun. 2017.
- Webb, K. M. & Calderón, F. J. (2015). Mid-Infrared (MIR) and Near-Infrared (NIR) Detection of *Rhizoctonia solani* AG-2-2 IIIB on Barley-Based Artificial Inoculum. *Applied Spectroscopy*, 69 (10), 1129-1136.

(VERSÃO PRELIMINAR)

ARTIGO 2

Modelagem geoestatística de funções de covariância espaçotemporal estacionárias da Sigatoka amarela em cultura de bananeira

Artigos submetidos ou em processo de submissão

Julia Dal Poggetto Rodrigues¹ - Marcelo de Carvalho Alves¹ -
Aurivan Soares de Freitas² - Edson Ampelio Pozza³ - Henrique José
de Paula Alves⁴ - Marcelo Silva de Oliveira⁴

¹Engineering Department, Federal University of Lavras, PO BOX
3037, CEP 37200-000, Lavras, MG, Brazil.

²University of Vale do Rio Verde, Av. Castelo Branco, 82, Chácara
das Rosas, CEP 37410-000, Três Corações, MG, Brazil.

³Plant Pathology Department, Federal University of Lavras, PO BOX
3037, CEP 37200-000, Lavras, MG, Brazil.

⁴Department of Statistics, Federal University of Lavras, PO BOX
3037, CEP 37200-000, Lavras, MG, Brazil.

Autor para correspondência: Marcelo de Carvalho Alves
marcelocarvalhoalves@gmail.com

Preparado em concordância com as normas do periódico

“Precision Agriculture”

(Versão preliminar – em processo de submissão)

Resumo

A produção de banana é afetada pela Sigatoka amarela, uma entre as causadoras de lesões nas folhas, que acarreta a redução da área fotossintética da planta e, conseqüentemente, a qualidade da fruta e a produção. O presente estudo teve como objetivo analisar o progresso espaçotemporal da Sigatoka amarela utilizando a geoestatística e comparar os modelos de covariância espaçotemporais separáveis e não separáveis com diferentes métodos de ajuste. O experimento foi realizado em um bananal da variedade Prata-Anã, que apresentava alta severidade da doença, sem qualquer medida de controle, o que possibilitou o estudo do comportamento em condições naturais. O modelo separável Duplamente Exponencial e o modelo não separável de Gneiting foram testados com os métodos de ajustes Weight Least Squares (WLS), Restricted Maximum Likelihood (REML) e Likelihood Pairwise. O modelo de Gneiting, método de ajuste WLS, permitiu reduzir as incertezas da predição espacial e temporal da doença, bem como caracterizar o padrão espaçotemporal do monociclo da doença.

Palavras chave: *Musa* spp.. *Pseudocercospora musae*. Gneiting. Weight Least Squares.

Introdução

A banana (*Musa* spp.) está entre as frutas mais consumidas no mundo, constituindo importante papel social e econômico na geração de emprego e renda de pequenos, médios e grandes produtores (Fioravanço, 2003). O Brasil é o quarto maior produtor mundial de banana (FOA, 2017) e, dentre os estados brasileiros, Minas Gerais ocupa o terceiro lugar na produtividade da fruta (IBGE, 2017).

A bananeira é afetada por diversas doenças, entre as quais se destaca a Sigatoka amarela, cujo agente etiológico é o fungo *Mycosphaerella musicola* Leach na fase sexuada ou *Pseudocercospora musae* Zimm na fase assexuada (Cordeiro e Matos, 2005). O fungo causador de lesões nas folhas é o responsável pela redução da área fotossintética da planta e, conseqüentemente, da produção e qualidade da fruta (Castelan et al., 2013).

Mas, para que ocorra a doença, é necessários a interação entre três fatores: o patógeno, o ambiente favorável e a planta susceptível. Além desses, de acordo com Pozza e Pozza (2012), a questão nutricional também é um fator influenciador, visto que bananais em situação de excesso ou deficiência nutricional, apresentam predisposição a doenças. No entanto, de acordo com Freitas et al. (2017), antes que estes sintomas sejam observados, o patógeno precisa germinar e infectar a planta, atravessando as barreiras estruturais e de resistência química para estabelecer a relação de parasitismo com o hospedeiro no período latente de 50 dias.

O progresso da doença não acontece somente ao longo da área do plantio, no espaço, mas também ao longo dos dias, do tempo. E para isso, é preciso modelar as dependências espaçotemporais

resultantes de processos dinâmicos, que evoluem tanto no espaço quanto no tempo (Montero e Fernández-Avilés, 2015).

Entre os modelos geoestatísticos que analisam as estruturas espaçotemporais, há os modelos que permitem isolar a parte somente espacial da parte somente temporal, chamados de separáveis (Oliveira et al., 2006) e os modelos que visam a capturar a interação espaçotemporal, que são chamados de não separáveis (Huser e Davison, 2013; Montero e Fernández-Avilés, 2015; Angel et al., 2016).

A escolha da função de covariância é um aspecto central no procedimento de predição (Montero e Fernández-Avilés, 2015) e o ajuste estatístico pode ser usado para escolher os modelos pré-selecionados e a estimativa dos parâmetros.

Diante do impacto que a Sigatoka amarela causa nas plantações de bananeira, o presente trabalho teve como objetivo fazer a análise espaçotemporal da doença, utilizando a geoestatística e comparando modelos de covariância espaçotemporais separáveis e não separáveis com diferentes métodos de ajuste.

Material e Métodos

Com o intuito de realizar a predição espaçotemporal da Sigatoka amarela, foi realizado, em um bananal, um experimento com base em dados coletados *in situ*, conforme descrito em detalhes por Freitas et al. (2015).

Área de estudo

Localizada no sítio Vale dos Ventos, município de Lavras/MG (Fig. 1), o bananal da variedade Prata-Anã, apresentava uma área total de 1,2 ha com espaçamento de 4m x 3m entre as plantas.

O clima da região, em que o sítio está inserido, é do tipo Cwb (tropical de altitude), apresenta chuvas durante todo o ano, sendo mais concentradas no verão (Fig. 2).

O bananal foi selecionado, devido à alta severidade da Sigatoka amarela e por não possuir qualquer medida de controle, permitiu o estudo do comportamento da doença em condições naturais de infecção.

Para o início do experimento, em 2012, foram georreferenciados 27 pontos espaçados em malha regular de 18 x 18m (324 m²), utilizando GPS Geodésico modelo Trimble 4600.

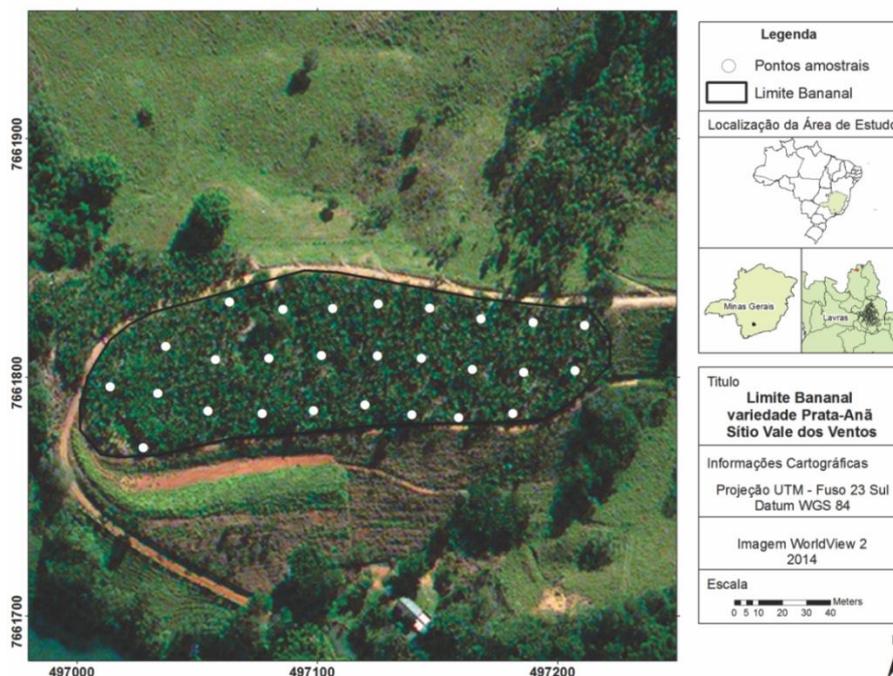


Fig. 1 Localização do bananal variedade Prata-anã, Sítio Vale dos Ventos, município de Lavras/MG, onde foram coletados os dados *in situ* em malha amostral com 27 pontos para avaliar a severidade da Sigatoka amarela.

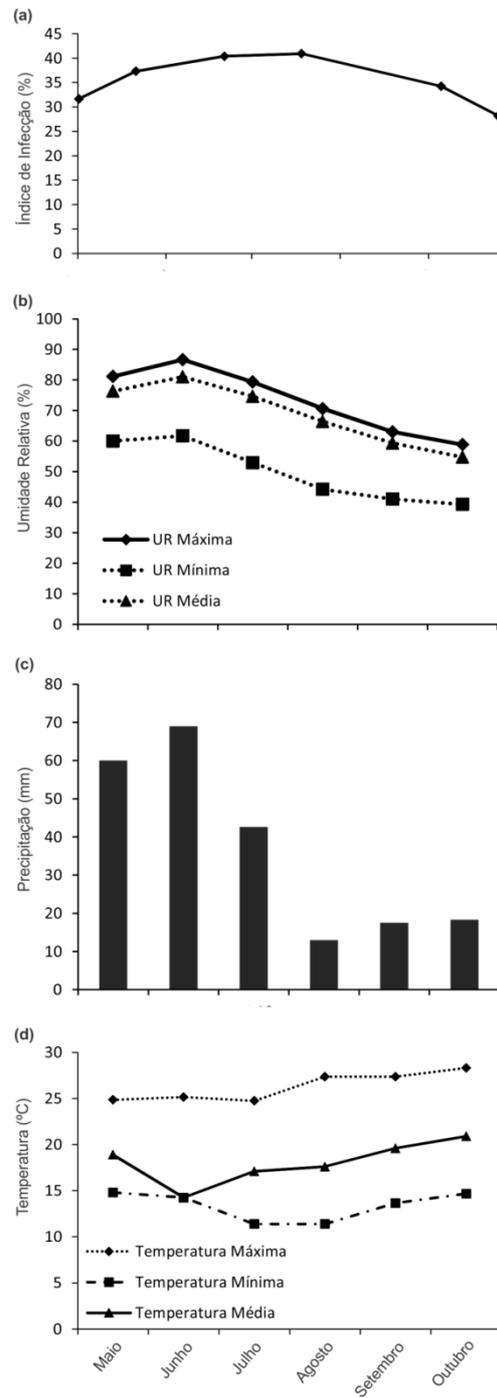


Fig. 2 Curva de progresso das taxas médias de infecção da Sigatoka Amarela (a), valores máximo, médio e mínimo de umidade relativa (b), temperatura máxima, média, mínima (c), precipitação (d) entre os meses de maio e outubro de 2012.

Avaliação da doença

A severidade da Sigatoka amarela foi avaliada uma vez por mês, entre maio e outubro de 2012, sempre na mesma planta, com o auxílio da escala diagramática proposta por Stover (1972) e modificada por Gauhl (1994). A severidade da doença foi transformada em índice de infecção (ii), conforme Freitas et al., (2015):

$$\text{Índice de infecção} = \left[\sum nb / (N)T \right] * 100$$

Em que:

n é o número de folhas em cada nível da escala de Stover modificada por Gauhl,

b o grau da escala,

N o número de graus empregados na escala e

T o número total de folhas avaliadas.

Estatística Descritiva

A análise geoestatística foi utilizada para descrever a variabilidade espaçotemporal da Sigatoka amarela.

As avaliações da severidade foram realizadas em seis épocas, uma vez por mês e depois transformadas para índice de infecção. Para realizar a análise temporal, as datas foram contadas em dias. A primeira avaliação, dia 1, foi realizada em 23/05/2012 (ii1); a segunda, dia 21, em 13/06/2012 (ii2); a terceira, dia 51, em 13/07/2012 (ii3); a quarta, dia 78, em 09/08/2012 (ii4); a quinta, dia 98, em 27/09/2012 (ii5) e a sexta, dia 119, em 17/10/2012 (ii6).

Foram comparados modelos de covariogramas, Duplamente Exponencial e Gneiting, bem como os métodos de ajuste, WLS, REML, Lik Pairwise, a fim de caracterizar a estrutura e a magnitude espaçotemporal da doença (Fig. 3).

Métodos de Ajuste

Os métodos de ajuste foram utilizados para a interpretação da estrutura de correlação espaçotemporal nos procedimentos da krigagem.

O método dos Mínimos Quadrados Ponderado (Weight Least Squares - WLS) foi testado para os dois modelos de covariância, separável e não separável. No modelo separável, Duplamente Exponencial, testou-se o ajuste com a modelagem da tendência de 1ª ordem e sem a modelagem. No modelo de Gneiting, não separável, testou-se somente o ajuste em que a tendência de 1ª ordem foi modelada.

Já o método da Máxima Verossimilhança Restrita (Restricted Maximum Likelihood - REML) foi utilizado por maximizar a função de densidade de probabilidades, em relação aos efeitos fixos e aos componentes de variâncias dos efeitos aleatórios do modelo (Oliveira, 2006). Por fim, o método da Probabilidade de Pares (Likelihood Pairwise - Lik Pairwise) foi testado somente no modelo não separável de Gneiting (Fig. 3).

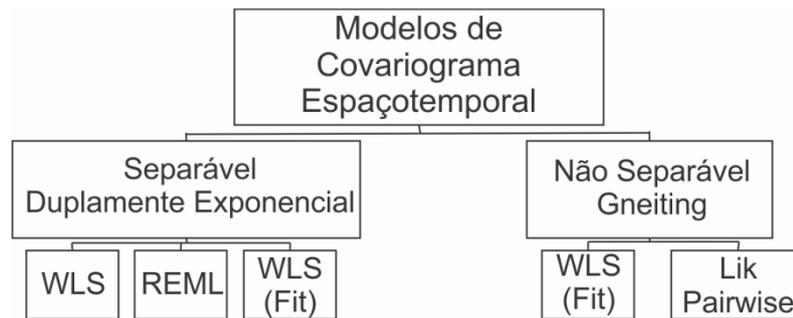


Fig. 3 Fluxograma da metodologia geoestatística, na qual foram selecionados covariogramas espaço-temporais separáveis (esquerda) e não separáveis (direita) e os respectivos métodos de ajuste Weight Last Squares (WLS) para os dados originais e em que a tendência foi modelada (Fit), Restricted maximum likelihood (REML), e Likelihood Pairwise (Lik Pairwise).

Modelos de Covariância

O modelo Duplamente Exponencial:

$$C(h, u) = \exp(- \| h \| / a_s - | u | / a_t)$$

em que, h é a distância no espaço, u distância no tempo, a_s é alcance espacial e a_t alcance temporal.

Já o modelo de Gneiting (2002):

$$C(h, u, \theta) = C_1 \frac{1}{(a | u |^{2\alpha} + 1)} \exp\left(\frac{-c \| h \|^{2\gamma}}{(a | u |^{2\alpha} + 1)^{\beta\gamma}}\right)$$

em que c é a escala no espaço, a é a escala no tempo, C_1 é o patamar, γ é a potência no espaço, α é a potência no tempo, β é a força de interação entre o tempo e o espaço, h é a distância no espaço e u é a distância no tempo.

Krigagem

O preditor linear de krigagem (Sherman, 2011), com notação adaptada, foi definido como:

$$\hat{Z}(s_0, t) = \mu + \sigma' \sum^{-1} (z - \mu_2)$$

em que μ_2 é a média espacial; o termo $\sigma' \Sigma^{-1}$ é conhecido como pesos de krigagem.

Variância da Krigagem ordinária

A variância de krigagem (Sherman, 2011) ordinária foi definida por:

$$\sigma_k^2 = \sum_{i=1}^n \lambda_i [Z(s_1, t_1) - \hat{Z}(s_0, t_0)]^2$$

em que $\lambda_i = \sigma' \Sigma^{-1}$

Softwares utilizados

A análise geoestatística foi realizada no software R (2015), um software estatístico livre, assim como os pacotes “GeoR” (Diggle e Ribeiro Junior, 2016), “CompRandFld” (Padoam e Bevilacqua, 2015), “scatterplot3d” (Ligges et al., 2017) e “fields” (Nychka et al., 2017).

Os valores de predição e variância da krigagem calculados foram exportados em texto (.txt) para o SIG QGis e convertidos, primeiramente, para o vetor ponto, no formato shapefile (.shp) e, posteriormente, transformados em dados matriciais e inseridos na medida de 1,5m x 1,5m ao pixel. Os dados foram projetados na Universal Transversa de Mercator (UTM), Datum WGS 84, zona 23 sul, com o intuito de adequá-los à base de dados de campo.

Resultados e Discussão

A curva de progresso da taxa média de infecção da Sigatoka amarela apresentou valor mais alto (40,92%) no mês referente a agosto de 2012. O valor médio da umidade relativa apresentou valor mais alto (81%) nos meses de junho e de agosto, em que houve um pico da doença, a umidade relativa foi de 66,4%. A precipitação

apresentou os maiores valores em junho, 69 mm, e no mês de agosto foi de 13mm. A temperatura média em agosto foi de 17,6°C (Fig. 2).

Os autores Rocha et al. (2012) encontraram dois picos da doença, sendo o segundo o que apresentou características semelhantes ao encontrado nesse trabalho, na estação seca, com temperatura média de 18,4°C, umidade relativa de 76,3% e baixos valores de precipitação. Dessa maneira, à medida que houver o declínio da temperatura e o aumento da umidade relativa ocorreu o aumento da doença. Na estação seca, houve a interrupção na emissão das folhas e o declínio do crescimento da bananeira, o que pôde explicar o progresso da doença (Wardlaw, 1961).

Observou-se a assimetria, os valores da média e da mediana nas avaliações 09/27/2012 (ii5) e 10/17/2012 (ii6) foram próximos e o coeficiente de variação dessas duas épocas foram 38,14% e 45,09%, respectivamente. Os valores de curtose e assimetria na avaliação ii6, foi acima de 1,0 (Tabela 1).

Tabela 1 Estatísticas descritivas da severidade da Sigatoka amarela transformada em índice de infecção (ii) para as avaliações realizadas em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 08/09/2012 (ii4), 09/27/2012 (ii5) e 10/17/2012 (ii6).

	ii1 (%)	ii2 (%)	ii3 (%)	ii4 (%)	ii5 (%)	ii6 (%)
Mínimo	6,000	1,670	5,000	13,890	5,000	5,000
1° Quadrante	23,950	25,660	29,760	26,770	27,780	22,020
Mediana	33,300	41,670	42,590	44,440	34,260	27,270
Média	31,670	37,330	40,390	40,920	34,240	28,160
3° Quadrante	41,000	49,240	54,080	50,760	39,810	31,250
Máximo	60,000	66,670	65,380	64,290	64,290	64,290
Desvio Padrão	15,480	18,120	16,790	14,920	13,060	12,700
Coefficiente de Variação	48,870	48,540	41,560	36,460	38,140	45,090
Curtose	-0,502	-0,817	-0,775	-1,064	0,497	2,627
Assimetria	-0,111	-0,346	-0,386	-0,345	-0,016	1,060

Após a modelagem da tendência de 1ª ordem dos dados originais os *outliers* permaneceram, o que de fato é uma característica da biologia da espécie, *P. musae* (*M. musicola*). Ademais, a modelagem realizada com a remoção da tendência resultou em mapas de desvio padrão da krigagem com menor erro comparado aos mapas em que os dados não foram modelados.

Comparando os valores estimados para os modelos separáveis e não separáveis (Tabela 2), em relação à escala do tempo (*a*) o modelo de Gneiting, método de ajuste WLS, foi o que apresentou o valor mais próximo, 51,244, do período latente do fungo, que corresponde ao tempo entre a infecção do patógeno na planta e a reprodução do patógeno, 50 DAI (dias após a inoculação), de acordo com Freitas et al. (2017) que analisaram o processo de infecção do *P.*

musae, da germinação à esporulação, em folhas de bananeira, utilizando microscopia eletrônica de varredura. Já Rocha et al. (2012) encontraram uma latência média de 29 dias, ao analisarem o índice de infecção da *M. musicola* em um bananal localizado no município de Coronel Pacheco/MG.

Tabela 2 Comparação entre os parâmetros estimados para os modelos Duplamente Exponencial (Exp_Exp) e Gneiting, com os métodos de ajuste Weight Least Squares (WLS), Restricted maximum likelihood (REML) e Likelihood Pairwise (Lik Pairwise) em dados originais e dados em que a tendência foi modelada (Fit).

Modelos	Método de ajuste	Parâmetros						
		Efeito pepita	Escala no espaço	Escala no tempo	Patamar	Potência no espaço	Potência no tempo	Força da interação
		(C ₀)	(c)	(a)	(C ₀ +C ₁)	(γ)	(α)	(β)
Exp_Exp	WLS (Fit)	12,73	14,970	114,310	188,320			
Exp_Exp	REML	73,9	70,940	65,320	238,290			
Exp_Exp	WLS	2,613	11,819	86,390	256,270			
Gneiting	WLS (Fit)	5,902	18,290	51,244	192,650	2,000	0,668	1,000
Gneiting	Lik Pairwise	1767,00	28670	15790	251500	730,6	1628	0

O modelo não separável Gneiting com o método de ajuste WLS apresentou força de interação (β), 1,000, que segundo Gneiting (2002), varia de 0 a 1, sendo o maior valor o que indica a melhor interação espaço-tempo (Tabela 2). A força de interação também pode ser observada no modelo de covariograma, o qual apresentou uma suavização maior que nos demais modelos (Fig. 4). Huser e Davison (2013), na análise de dados de precipitação por hora, na Suíça, utilizaram o mesmo modelo de Gneiting, porém com o método de ajuste Likelihood Pairwise, obtiveram uma interação entre os dados de 0,99. Nos dados de índice de infecção da Sigatoka amarela analisados

nesse trabalho, o método Likelihood Pairwise apresentou menor força de interação.

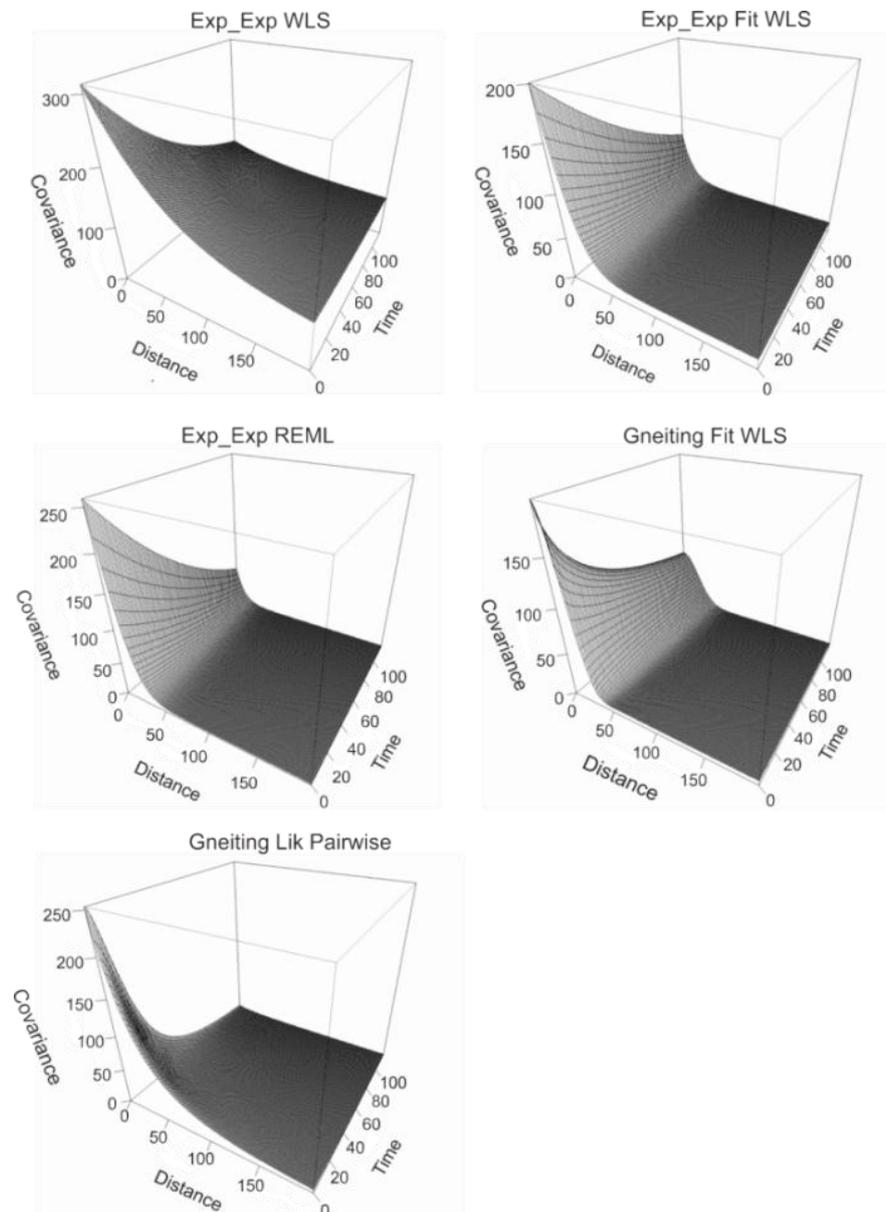


Fig. 4 Modelos de covariogramas espaço-tempo separáveis, Duplamente Exponencial (Exp_Exp), e não separáveis, Gneiting, à direita os modelos que a tendência foi modelada (Fit) e à esquerda os que não apresentam os modelos ajustados pelos métodos Weight Last Squares (WLS), Restricted maximum likelihood (REML), Likelihood Pairwise (lik pairwise).

Montero e Fernández-Avilés (2015) afirmaram que o modelo de Gneiting capturou as características espaçotemporais melhor que os demais modelos em relação às taxas de monóxido de carbono (CO), em Madri, Espanha, devido à sua alta flexibilidade, bem como o fato de incluir explicitamente um parâmetro de interação espaço-tempo com grande influência na forma da função.

Da mesma forma, os autores Angel et al. (2016) também utilizaram o mesmo modelo, implementado no pacote `CompRandomFld`, para remover efeitos de nuvem, sombra e poeira de imagens hiperspectrais de uma região agrícola na Arábia Saudita.

Os valores dos mapas de predição e de desvio padrão da krigagem ordinária (Fig. 5, 6, 7, 8 e 9) foram ajustados de acordo com o modelo que apresentou o menor valor de variância de predição.

Observou-se uma característica comum entre os modelos analisados. Os valores mais altos de predição (≥ 40) disseminaram sentido à região leste da área de estudo ao longo do tempo, indicando que houve o progresso da doença na região do bananal caracterizada de acordo com Freitas et al. (2015), como de maior altitude, variando de 850 a 855m.

O modelo Duplamente Exponencial, com os métodos de ajuste WLS, em que a tendência foi modelada (Fig. 5), o WLS sem modelagem da tendência (Fig. 6) e o REML (Fig. 7) apresentaram características semelhantes nas avaliações referentes ao mês de junho (ii2) e ao mês de agosto (ii4), em que houve um aumento dos maiores valores de predição (≥ 40) na região central da área de estudo.

Os menores valores de predição (≤ 25) do modelo de Gneiting, método de ajuste WLS, em que a tendência foi modelada (Fig. 8),

foram mais acentuados em relação aos demais modelos e na região central da área de estudo.

Já o modelo de Gneiting, método de ajuste Likelihood Pairwise (Fig. 9) apresentou os menores valores de predição (≤ 25) em uma área reduzida comparada aos demais modelos. Os menores valores de predição encontraram-se em áreas em que o teor de areia era baixo e os valores de silte e matéria orgânica eram altos, conforme descrito em Freitas et al. (2015).

Em relação ao desvio padrão da krigagem, observou-se que o modelo Duplamente Exponencial e os métodos WLS (Fig. 5 e 7) e REML (Fig. 6) apresentaram erro maior que o modelo de Gneiting (Fig. 8 e 9). Os menores valores concentraram nos pontos, em que as amostras foram coletadas.

Oliveira et al. (2006) utilizaram o modelo exponencial e os métodos de ajuste REML e ML, para analisar apenas a dependência espacial do teor de cálcio no solo, e o REML foi o método de ajuste que apresentou melhores resultados nos mapas de predição, com as regiões mais bem definidas nos locais, onde se encontraram os menores valores nos mapas de variância de predição.

O desvio padrão do modelo de Gneiting, entre os métodos WLS (Fig. 8) e Likelihood Pairwise (Fig. 9), foi menor no método WLS, em que a tendência foi modelada. Os valores além de não se concentrarem somente nos pontos amostrais, apresentaram valores de até 7%.

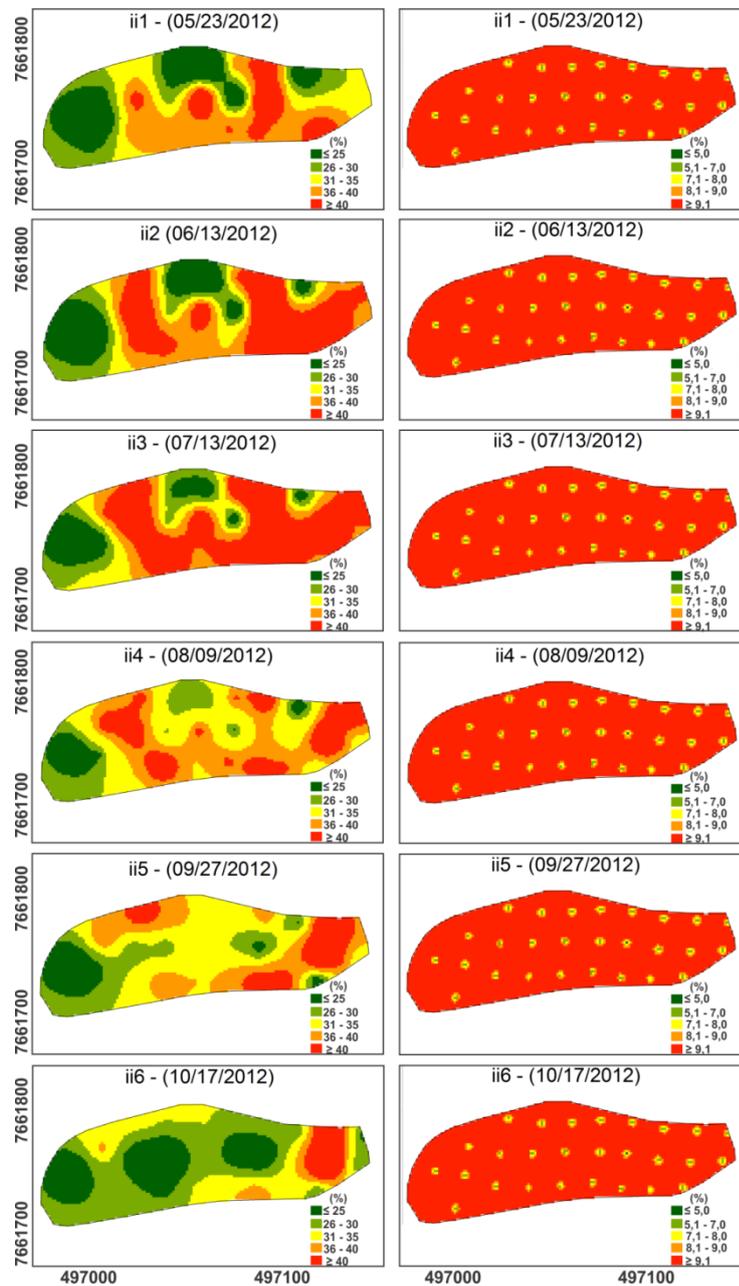


Fig. 5 Mapas de predição (esquerda) e de desvio padrão (direita) da krigagem do modelo de covariância Duplamente Exponencial (Exp_Exp) método Weight Last Squares (WLS), em que a tendência foi modelada, para a avaliação da severidade da Sigatoka amarela transformada em índice de infecção (ii) avaliadas na Fazenda Vale dos Ventos, município de Lavras/MG, em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 08/09/2012 (ii4), 27/09/2012 (ii5) e 17/10/2012 (ii6).

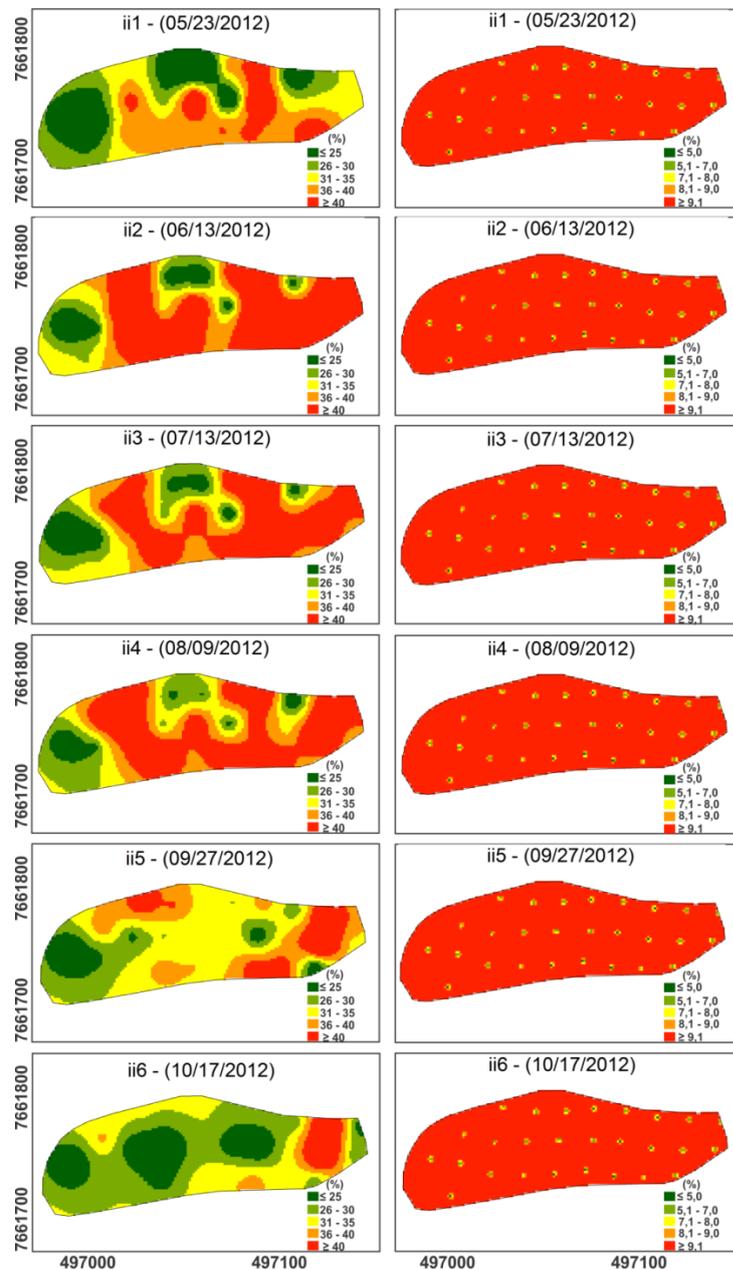


Fig. 6 Mapas de predição (esquerda) e de desvio padrão (direita) da krigagem do modelo de covariância Duplamente Exponencial (Exp_Exp) método Restricted maximum likelihood (REML) para a avaliação da severidade da Sigatoka amarela transformada em índice de infecção (ii) avaliadas na Fazenda Vale dos Ventos, município de Lavras/MG, em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 08/09/2012 (ii4), 27/09/2012 (ii5) e 17/10/2012 (ii6).

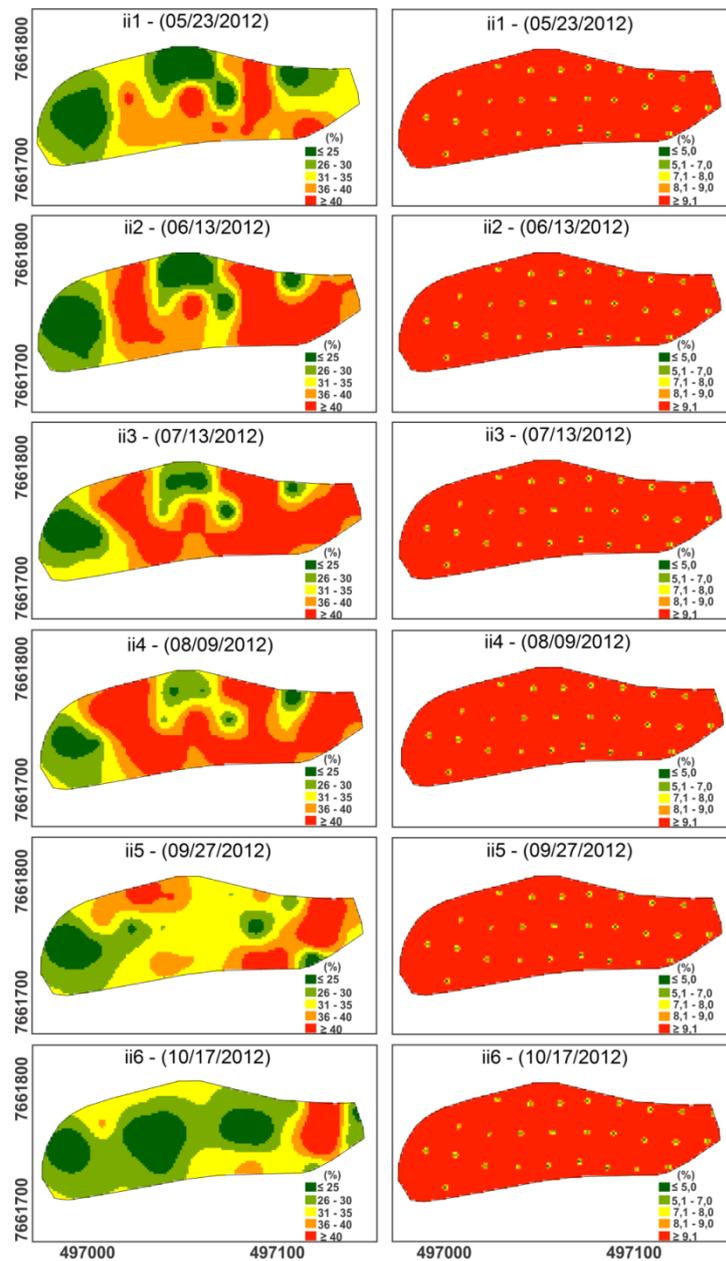


Fig. 7 Mapas de predição (esquerda) e de desvio padrão (direita) da krigagem do modelo de covariância Duplamente Exponencial (Exp_Exp) método Weight Last Squares (WLS) para a avaliação da severidade da Sigatoka amarela transformada em índice de infecção (ii) avaliadas na Fazenda Vale dos Ventos, município de Lavras/MG, em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 08/09/2012 (ii4), 27/09/2012 (ii5) e 17/10/2012 (ii6).

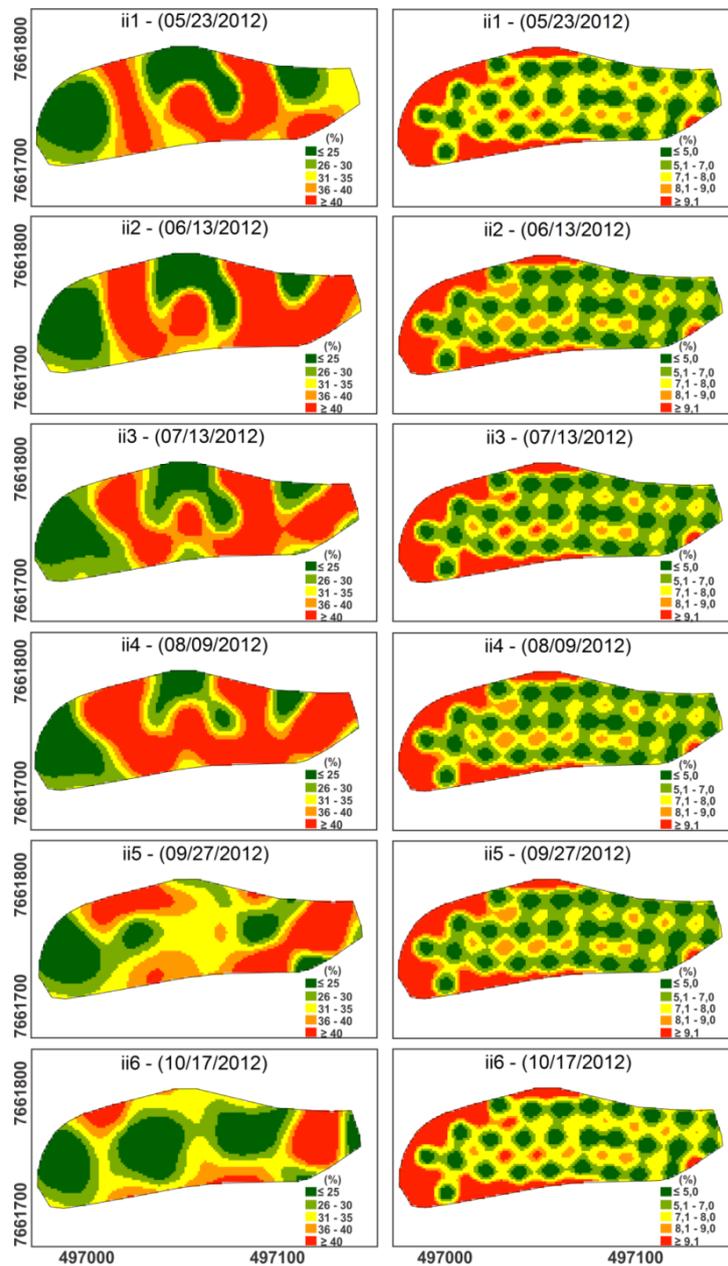


Fig. 8 Mapas de predição (esquerda) e de desvio padrão (direita) da krigagem do modelo de covariância Gneiting, método Weight Last Squares (WLS), em que a tendência foi modelada, para a avaliação da severidade da Sigatoka amarela transformada em índice de infecção (ii) avaliadas na Fazenda Vale dos Ventos, município de Lavras/MG, em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 08/09/2012 (ii4), 27/09/2012 (ii5) e 17/10/2012 (ii6).

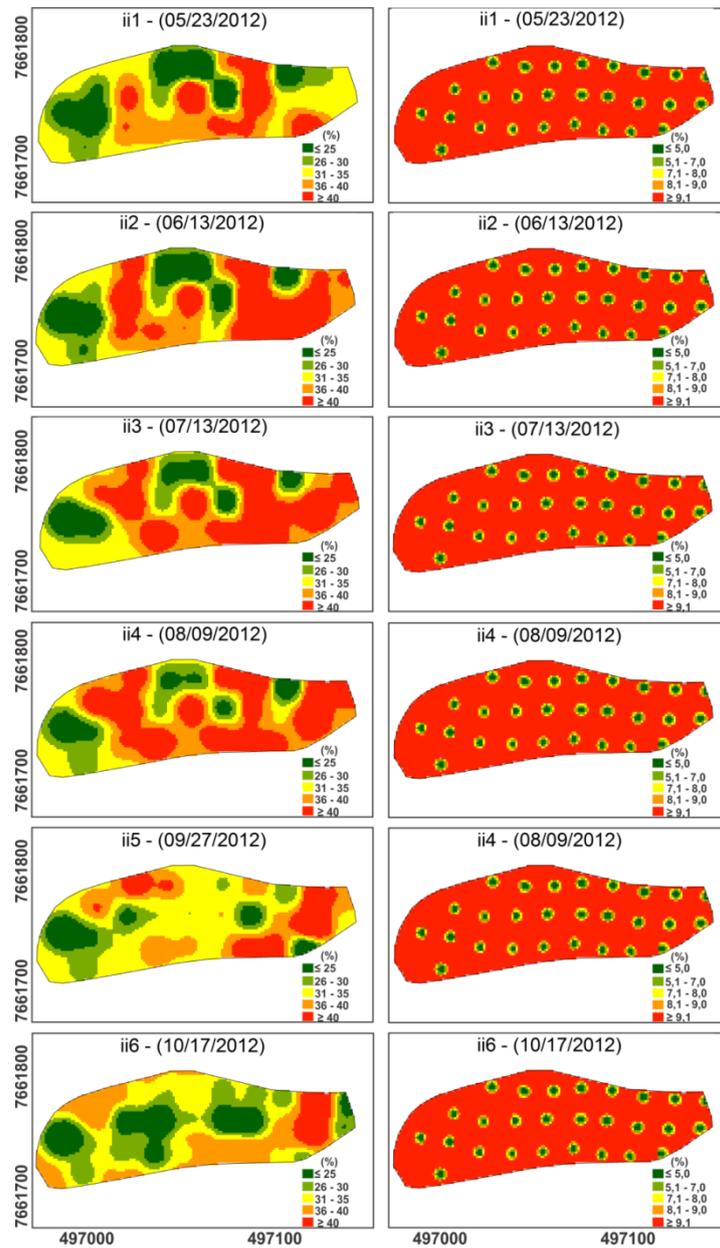


Fig. 9 Mapas de predição (esquerda) e de desvio padrão (direita) da krigagem do modelo de covariância Gneiting método Likelihood Pairwise (Lik Pairwise), em que a tendência foi modelada, para a avaliação da severidade da Sigatoka amarela transformada em índice de infecção (ii) avaliadas na Fazenda Vale dos Ventos, município de Lavras/MG, em 23/05/2012 (ii1), 13/06/2012 (ii2), 13/07/2012 (ii3), 08/09/2012 (ii4), 27/09/2012 (ii5) e 17/10/2012 (ii6).

Montero e Fernández-Avilés (2015) também obtiveram um melhor comportamento utilizando a função de covariância espaçotemporal não separável de Gneiting, porém usando outra técnica de validação, o erro quadrático médio (RMSE), o qual foi mais baixo. Freitas et al. (2015), analisaram somente a dependência espacial da Sigatoka amarela pelo modelo esférico na mesma área deste trabalho e obtiveram valores do erro de krigagem de até 20%, nas épocas ii2 e ii3, valores maiores do que os encontrados nos modelos em que analisaram o espaço tempo, de maneira não separável.

Diante disso, a metodologia empregada possibilitou verificar a variação espaçotemporal da doença com o menor erro entre os demais modelos ajustados, inclusive o ajustado ao progresso espacial por Freitas et al (2015).

Conclusão

Com o uso do modelo Gneiting, método de ajuste WLS, em que a tendência foi modelada, foi possível reduzir as incertezas de predição espacial e temporal da doença, bem como caracterizar o padrão espaçotemporal do monociclo da doença, de acordo com as condições climáticas observadas na área estudada.

Referências

- Alves, M. C., Silva, F. M., Moraes, J. C., Pozza, E. A., Oliveira, M. S., Souza, J. C., Alves, L. S. (2011). Geostatistical analysis of the spatial variation of the berry borer and leaf miner in a coffee agroecosystem. *Precision Agriculture*, 12 (1), 18-31.
- Angel, Y., Houborg, R., McCabe, M. F. (2016). Removal of clouds, dust and shadow pixels from hyperspectral imagery using a non-separable and stationary spatio-temporal covariance model. *Remote Sensing for Agriculture, Ecosystems, and Hydrology* doi: 10.1117 / 12.2241518.
- Castelan, F.P., Abadie, C., Hubert, O., Chilin-Charles, Y., De Bellaire, L. L., Chillet, M. (2013). Relation between the severity of Sigatoka disease and banana quality characterized by pomological traits and fruit green life. *Crop Protection*, 50, 61–65.
- Cordeiro, Z. J.M; Matos, A. P. (2005). *Expressão da Resistência de Variedades de Banana à Sigatoka-Amarela*. Fitopatologia brasileira, Brasília, 30, (5), 532-534.
- Diggle, P. J., Ribeiro Júnior, P. J. (2016). *geoR: Analysis of Geostatistical Data*. R package version 1.7-5.2 URL <https://cran.r-project.org/web/packages/geoR/geoR.pdf>.
- Faostat (2017). Food and Agriculture Organization of the United Nations Statistics Division. Production/Crops. Disponível em: <<http://faostat3.fao.org/browse/Q/QC/E>. >. Acesso em: 04 set. 2017.
- Fioravanco, J. C. (2003). Mercado mundial da banana: produção, comércio e participação brasileira. *Informações econômicas*. 33, 15-27.
- Freitas, A. S., Pozza, E. A., Alves, M. C., Coelho, G., Rocha, H. S., Pozza, A. A. A. (2015). Spatial distribution of Yellow Sigatoka Leaf Spot correlated with soil fertility and plant nutrition. *Precision Agriculture*. 17 (1), 93-107.
- Freitas, A. S., Pozza, E. A., Moreira, S. I., Soares, M. G. O., Silva, H. R., Alves, E. (2017) Infection process of *Pseudocercospora musae* on banana leaf. *Phytoparasitica*, doi: 10.1007 / s12600-017-0596-8.
- Gauhl, F. (1994). Epidemiology and Ecology of Black Sigatoka (*Mycosphaerella fijiensis* Morelet) on Plantain and banana (*Musa* spp) in Costa Rica, Central América. Montpellier: INIBAP.
- Gneiting, T. (2002). Nonseparable, stationary covariance functions for space-time data. *Journal of the American Statistical Association*, 97 (458), 590–600.

- Huser, R. & Davison, A. C. (2013). Space-time modeling of extreme events. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 74, 439-461.
- IBGE (2017). Instituto Brasileiro de geografia e Estatística. Produção agrícola municipal. Disponível em: <<http://www.sidra.ibge.gov.br/>>. Acesso em: 27 ago. 2017.
- Ligges, U., Maechler, M., Schnackenberg, S. Scatterplot3d 3D Scatter Plot. R package version 0.3-40, URL <https://cran.r-project.org/web/packages/scatterplot3d/scatterplot3d.pdf>. 2017.
- Montero, J.M., Fernández-Avilés, G., Mondejar-Jiménez, J., Vargas-Vargas, M. (2015). A spatio-temporal geostatistical approach to predicting pollution levels: The case of mono-nitrogen oxides in Madrid. *Computers, Environment and Urban Systems*, (37), 95–106.
- Montero, J.M. & Fernández-Avilés, G. (2015). The role of visualisation in the choice of stationary non-separable space-time covariance functions: na application to air pollution data. *International Journal of Geographical Information Science*. 29 (10), 1887-1909.
- Nychka, D., Furrer, R., Paige, J., Sain, S. (2017) *fields*: Tools for Spatial Data. R package version 9.0, URL <https://cran.r-project.org/web/packages/fields/fields.pdf>.
- Oliveira, M. C. N., Barbin, D., Silva, E. F., Macedo, J. R., Capeche, C. L., Hissa, H. R. (2006). Estimaco dos parâmetros de uma funo de covariânciã no estudo da variabilidade especial do teor de cálcio no solo. *Rev. Mat. Estat.*, 24 (4), 117-132.
- Padoan, S. A. & Bevilacqua, M. (2015). CompRandFld: Composite likelihood based Analysis of Random Fields. R package version 1.0.3-4, URL <http://CRAN.R-project.org/package=CompRandFld>.
- Pozza, E. A. & Pozza, A. A. A. (2012). *Relaço entre nutrio e as doenas de plantas: implicaes prticas*. In: simpsio avanos na otimizao do uso de defensivos agrcolas no manejo fitossanitrio, 12. Lavras. Anais... Lavras: UFLA, 2012. 1 CD-ROM.
- R: A language and environment for statistical computing. (2006). R Development Core Team, R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, <http://www.R-project.org>.
- Rocha, H. S., Pozza, E. A., Ucha, C. N., Cordeiro, Z. J. M., Souza, P. E., Sussel, A. A. B., Rezende, C. A. (2012). Temporal Progress of Yellow Sigatoka and Aerobiology of *Mycosphaerella musicola*

- Spores. *Journal of Phytopathology*, doi: 10.1111/j.1439-0434.2012.01897.x
- Sherman, M. (2011). *Spatial Statistics and Spatio-Temporal Data: Covariance Functions and Directional Properties*. United Kingdom: A John Wiley and Sons, Ltd, Publication.
- Stover, R. H. (1972). *Banana, plantain and Abaca disease*. Kew: Commonwealth Mycological Institute.
- Wardlaw, C. W. (1961) Leaf spot (Sigatoka disease). In: Wardlaw C. W. (ed.) *Banana Disease: Including Plantations and Abaca*. New York, NY, USA, Oxford University.

(VERSÃO PRELIMINAR)