

Potencial de Imagens Multiespectrais Sentinel 2 na Detecção de Nematoides na Cultura Cafeeira

RESUMO

Neste trabalho, avaliou-se o potencial do uso de imagens multiespectrais livres para identificar a infecção por nematoides em uma lavoura cafeeira. Adotou-se uma área de estudo com ocorrência de infecção por nematoides (*N. paranaenses*) na cultura cafeeira. Em segundo lugar, analisou-se a variação da resposta espectral do café infectados e sadio, em bandas do satélite Sentinel 2. Como hipótese, esperava-se que plantas saudáveis respondessem diferentemente das sadias. Assim, detectamos bandas cuja variação na refletância poderia auxiliar no processo de classificação de imagens. Assim, detectou-se essas variações, observando as bandas (vermelha, IVP, vermelho limítrofe 3-4). Posteriormente, fizemos a classificação da imagem (rede neural) aplicando diferentes combinações de imagens, considerando os resultados da etapa anterior, além de uma imagem representando o índice NDVI. A combinação das bandas Red, NIR e NDVI como entrada de classificação proporcionou o melhor resultado quando comparado com as outras combinações. Essa combinação permitiu detectar áreas de infecção por nematoides e realizar a classificação da imagem com 97,91% de acurácia. Portanto, obteve-se o potencial positivo do uso de imagens livres do Sentinel 2 para identificar infecções por nematoides em lavouras cafeeiras. Este é um resultado notável, uma vez que se produziu uma solução inovadora, de baixo custo e confiante.

PALAVRAS-CHAVE: Imagens Multiespectrais. Nematoides. Cafeeiro.

Laura Cristina Moura Xavier

xavier.lauramoura@gmail.com
<https://orcid.org/0000-0002-1903-0192>
Universidade Federal de Uberlândia (UFU), Monte Carmelo, Minas Gerais, Brasil.

Carlos Alberto Matias de Abreu Júnior

carlosalberto01032@hotmail.com
<https://orcid.org/0000-0001-5213-7325>
Universidade Federal de Uberlândia (UFU), Monte Carmelo, Minas Gerais, Brasil.

George Deroco Martins

deroco@ufu.br
<https://orcid.org/0000-0001-9738-2070>
Universidade Federal de Uberlândia (UFU), Monte Carmelo, Minas Gerais, Brasil.

João Vitor Meza Bravo

jvbravo@ufu.br
<https://orcid.org/0000-0002-5457-3192>
Universidade Federal de Uberlândia (UFU), Monte Carmelo, Minas Gerais, Brasil.

Bruno Sérgio Vieira

brunovieira@ufu.br
<https://orcid.org/0000-0001-8130-8100>
Universidade Federal de Uberlândia (UFU), Monte Carmelo, Minas Gerais, Brasil.

INTRODUÇÃO

O êxito na cafeicultura está relacionado a fatores como, por exemplo, a redução dos custos de produção, ao aumento na produtividade, a busca constante pela agregação de qualidade ao produto final, a preservação do meio ambiente, a conquista de novos mercados consumidores e a definição de políticas agrícolas para o crescimento do setor cafeeiro (SOUZA, 2000). O Brasil é um dos maiores produtores e exportadores de café no mundo, com destaque à região sul do Estado de Minas Gerais, que concentra cerca de 50% da produção nacional de café (CECAFÉ, 2018). O café brasileiro teve produtividade estimada de 28,41 a 30,54 sacas por hectare para o ano de 2018, desempenho que representa um recorde histórico de produção das lavouras cafeeiras (CONAB, 2018). Adicionalmente, estima-se que o total esperado para a produção de café no Brasil, no ano de 2018, se aproxima do intervalo que varia de 54,44 a 58,51 milhões de sacas (CONAB, 2018).

Analogamente, a projeção realizada pelo Conselho dos Exportadores de Café do Brasil – Cecafé aponta que até 2030 o consumo mundial de café deve aumentar por volta de 30 % e atingir 204,65 milhões de sacas. Assim, para que o Brasil conserve seu percentual de mercado desta commodity é necessário que a produção nacional aumente em escala compatível com a demanda externa, i.e., cerca de 16,17 milhões de sacas até 2030 (EMBRAPA, 2018).

Porém, a literatura destaca que, quando o aumento de produtividade no campo está aliado ao uso da tecnologia, é necessário estudar diversos fatores que podem causar a redução da produtividade e consequente redução da área plantada, neste caso, do café (SOUZA, 2000). Dentre os fatores relacionados, destaque especial pode ser dado à ocorrência de pragas e doenças durante o ciclo da cultura. No que se refere aos patógenos, pode-se dizer que os nematoides causam dano relevante, pois desencadeiam expressiva perda de produtividade, principalmente, à cultura de café (SOUZA, 2000).

Especificamente, os nematoides, segundo a Sociedade Brasileira de Nematologia (2016), são vermes microscópios e, geralmente, são encontrados em quantidades abundantes no solo e na água, são, também, parasitas de animais, insetos e plantas. No solo, podem ser classificados como nematoides de vida livre e ou nematoides fitopatogênicos, sendo que, nos solos agrícolas formam comunidades complexas, as quais comportam diferentes espécies. Alguns nematoides se alimentam de bactérias ou fungos com importância na decomposição e reciclagem de nutrientes. No entanto, uma parcela substancial da comunidade de nematoides do solo alimenta-se diretamente nas raízes das plantas, muitas vezes causando doenças (SBN, 2016).

No cafeeiro, os nematoides mais danosos são os causadores de galhas (*Meloidogyne* spp.) e os causadores de lesões radiculares (*Pratylenchus* spp.) (CAMPOS, 1997). As plantas atacadas apresentam diversos tipos de sintomas observados normalmente em reboleiras, como, por exemplo, a presença de galhas nas raízes, clorose nas folhas, redução e deformação do sistema radicular, decréscimo na eficiência das raízes em absorver água e nutrientes, menor crescimento da parte aérea, desfolha e menor produção, podendo causar a morte das plantas (IAC, 2007). A disseminação dos nematoides se dá por meio de mudas, da água em movimento, água de irrigação, cursos d'água, dos animais e,

principalmente, do próprio homem, que transporta nematoides em implementos agrícolas e veículos (IAC, 2007).

Atualmente, o Sensoriamento Remoto orbital tem recebido destaque em atividades relacionadas ao monitoramento agrícola, pois, as imagens multiespectrais possuem correlação com variáveis que afetam a produção da agricultura. Por exemplo, sabe-se que as imagens orbitais auxiliam práticas de monitoramento da produtividade como exemplo, o trabalho de Oliveira (2015), no qual estimou a produtividade da biomassa da cana-de-açúcar em função de índices de vegetação a partir de dados do sensor OLI/Landsat 8. Em trabalhos como o de Schultz et al. (2016) as imagens Landsat foram avaliadas para a classificação de culturas de cana-de-açúcar e soja via análise de imagens orientadas a objetos (OBIA/Random Forest). May (2017) analisou as mudanças no uso e cobertura do solo para verificar a expansão ou retração agrícola. Martins e Galo (2013) avaliaram o potencial de imagens multiespectrais RapidEye na detecção e discriminação de áreas de cana-de-açúcar infestadas por nematoides e *Migdolus fryanus*. Isso se deve ao refinamento significativo nas resoluções espacial, espectral e radiométrica de imagens, como a inserção de bandas espectrais específicas sensíveis à vegetação, como a do vermelho limítrofe, presentes nos sistemas orbitais comerciais WorldView 2 e 3, e na constelação RapidEye (MARTINS, 2014).

Quando se refere ao aumento de produtividade e à busca por agregar-se qualidade às culturas, é necessário que ocorra a diminuição das perdas causadas por fitoparasitas e pragas. Neste caso, no cenário tecnológico atual, a agricultura de precisão se destaca enquanto uma solução viável para detecção e monitoramento destas pragas. Assim sendo, é possível afirmar que o desenvolvimento da agricultura de precisão, apoiada em técnicas de sensoriamento remoto, contribui em práticas voltadas à detecção e mapeamento de fitoparasitas (MARTIS E GALO, 2015). Por exemplo, Lippert et al. (2015) utilizaram um espectroradiômetro ao analisarem o comportamento espectral de folhas de *Eucalyptus globulus* atacadas em quatro diferentes níveis de severidade pelo fungo *Mycosphaerella* ssp. em distintas posições na copa da árvore, considerando-se duas regiões do espectro eletromagnético: a saber, o visível e o infravermelho próximo. Similarmente, no estudo de Lemes (2017), identificou-se áreas com a ocorrência de *M. exigua* em seringais por meio do uso de índices espectrais de vegetação gerados a partir de imagens da constelação de satélites RapidEye; Boechat et al. (2014) estudaram a resposta espectral de plantas de feijoeiro infectadas por *Sclerotinia sclerotiorum*, agente causal do mofo-branco.

O estudo da vegetação por meio de técnicas de sensoriamento remoto é balizado pela existência de relações entre respostas espectrais do dossel e os parâmetros que caracterizam o estado de crescimento da planta. As respostas radiométricas são captadas pelos sensores e utilizadas para inferir o crescimento da vegetação e o estado fisiológico do vegetal (JENSEN, 2009). Segundo Cibula e Carter (1992), as regiões do espectro do visível que são mais sensíveis a estresse localizam-se nos intervalos de 530 a 640 nm e de 680 a 700 nm. Valores maiores de reflectância nas proximidades de 700 nm representam o que frequentemente é chamado de “deslocamento da borda vermelha para o azul”. Trata-se do deslocamento, em direção aos menores comprimentos de onda, do gradiente de transição vermelho para o infravermelho próximo (vermelho limítrofe), perceptível quando é feita a representação gráfica da reflectância pelo

comprimento de onda. O estudo de Martins e Galo (2015) comprovou que, especificamente na cultura cafeeira, existem mudanças perceptíveis na resposta espectral das culturas infectadas por nematoides, quando se observa imagens que representam informações no intervalo do infravermelho próximo 780 nm a 1070 nm, onde o cafeeiro sadio apresenta maior resposta do que as plantas infectadas por nematoides.

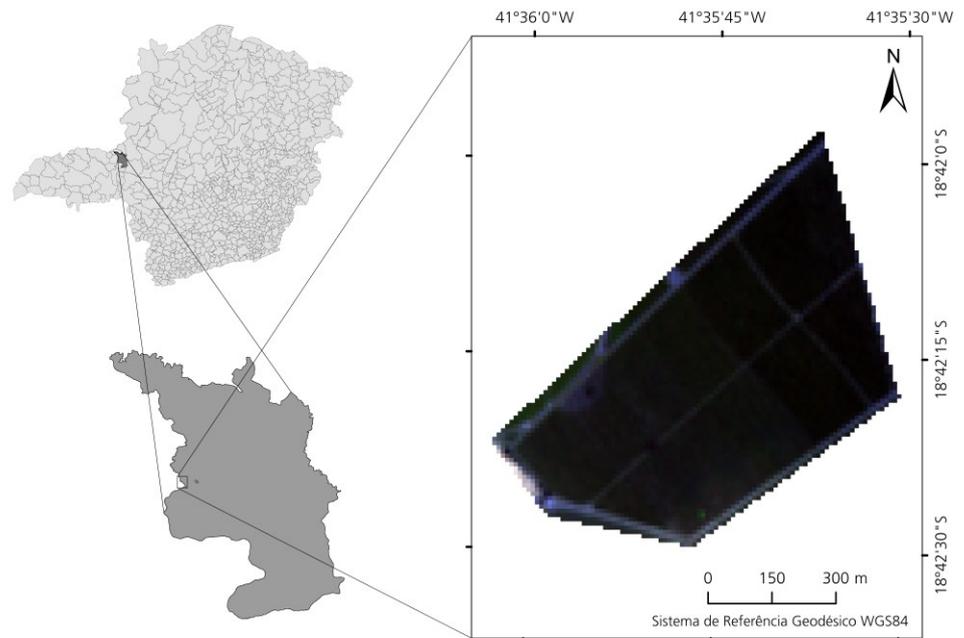
Portanto, levando-se em consideração a necessidade de se propor soluções ao monitoramento e detecção de pragas na cultura cafeeira, elaborou-se esta pesquisa, cujo o objetivo reside em avaliar o potencial das imagens Sentinel 2 para detecção de nematoides na cultura cafeeira. Considerou-se a utilização das imagens Sentinel 2, pois, visto que as mesmas são gratuitas, possuem uma resolução espacial compatível com a escala de ocorrência destas pragas bem como, contam com uma banda centrada no infra-vermelho próximo (IVP) e quatro bandas na região do vermelho limítrofe. Estas características permitem que se gere soluções cuja relação de “custo vs benefício” beneficiem o aumento de produção sem que haja substancial acréscimo de valor. Isso quer dizer que, o desenvolvimento deste tipo de estudo, apoiado em técnicas de sensoriamento remoto, contribui com a cafeicultura de precisão, no que se refere à detecção e ao mapeamento de nematoides, e colabora com a otimização do processo de produção, redução de custos e manejo mais ecológico.

MÉTODOS

ÁREA DE ESTUDO E MATERIAIS

Foi selecionada uma área de estudo com cultivo de café, em que foram coletadas amostras de raízes do cafeeiro e solo, e, após diagnóstico laboratorial, foi confirmada a ocorrência de nematoides nos talhões. Os nematoides detectados pertencem à espécie *Melodogyne paranaensis*. Esta área situa-se no município de Monte Carmelo, Estado de Minas Gerais, Brasil, conforme mostra o mapa da Figura 1.

Figura 1 – Mapa de Localização a partir da imagem Sentinel 2 de resolução espacial de 10 metros com combinação colorida RGB pelas bandas 4, 3 e 2



Fonte: Autoria própria (2018).

A área experimental Figura 1 é cultivada com café arábica (*Coffea arábica L.*) avaliada durante o ciclo de desenvolvimento da cultura. Foi possível realizar o posicionamento de locais de ocorrência da infestação e usar a informação georreferenciada para gerar o mapeamento.

Os instrumentos e dados utilizados foram:

- Receptor GPS de navegação Garmin E-trex para georreferenciamento das medidas tomadas *in situ*;
- Imagens multiespectrais do sistema Sentinel 2 B. Os Sentinel 2A e 2B são satélites que formam uma missão multiespectral imageadora administrada pela Agência Espacial Europeia para observação da terra, realizando coleta de dados sobre vegetação, solos e umidade, rios e áreas costeiras. Possui câmera multiespectral regular, com resolução espacial de 10 metros nas bandas azul, verde, vermelho e infravermelho próximo (IVP), e resolução espacial de 20 metros em quatro bandas centradas no intervalo do vermelho limítrofe. Os dois satélites juntos fazem revista a cada 5 dias, com resolução radiométrica de 12 bits por pixel e largura da faixa imageadora de 290 km. Os dados são disponíveis em Level-1C, onde têm a sua refletância calculada ao topo da atmosfera (TOA), com subpixel registro multiespectral, máscaras de nuvem e de terra/água também estão incluídos no produto. Suas imagens podem ser adquiridas de forma gratuita pelo site <https://earthexplorer.usgs.gov/>.

Tabela 1 – Especificações das Imagens Sentinel 2

Resolução Espacial (m)	Número da banda	Nome da Banda	Comprimento de onda médio (λ) (nm)
10	B02	Blue	490
	B03	Green	560
	B04	Red	665
	B08	NIR	842
20	B05	Red Edge 1	705
	B06	Red Edge 2	740
	B07	Red Edge 3	783
	B08A	Red Edge 4	865
	B11	SWIR 1	1610
	B12	SWIR 2	2190
60	B01	Aerossol	443
	B09	Water Vapor	940
	B10	Cirrus	1375

Fonte: Adaptado de ESA (2018).

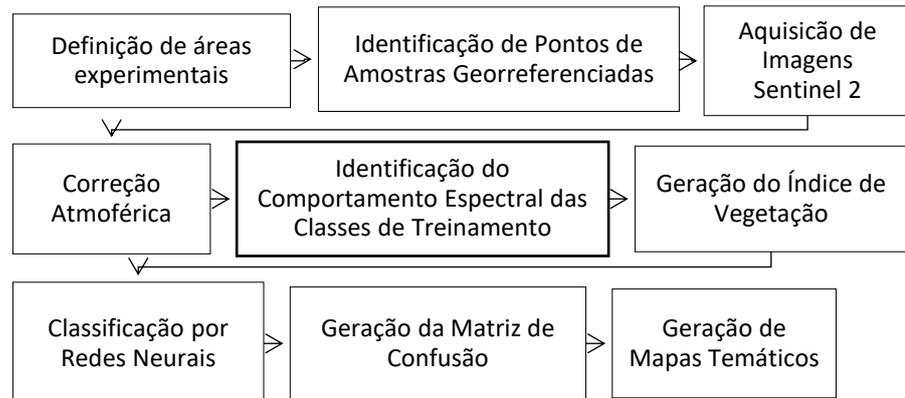
As bandas utilizadas foram as de resolução espacial de 10 metros (bandas azul, verde, vermelho e NIR) e 20 metros (*red edge 1,2,3 e 4*, SWIR 1 e 2) datadas de 01/03/2018, juntamente com as informações referentes ao satélite no site <https://earthexplorer.usgs.gov/>.

- c) Software SNAP (Sentinel Application Platform), desenvolvido pela Agência Espacial Europeia, para conversão do formato das bandas da imagem Sentinel 2.
- d) Software ENVI (Environment for Visualizing Images), versão 5.1, para correção atmosférica, classificações das imagens multiespectrais e geração dos parâmetros de avaliação da classificação de imagens.
- e) Software ArcMap, componente do ArcGis 10, utilizado para confecção dos mapas temáticos.

PROCEDIMENTOS METODOLÓGICOS

O método empregado neste estudo seguiu as etapas descritas no fluxograma da Figura 2.

Figura 2 – Fluxograma do Desenvolvimento Metodológico



Fonte: Autoria própria (2018).

Inicialmente foram definidas as áreas de estudo no cafeeiro, em que foi detectada a ocorrência de infestação por nematoides. Essa constatação foi feita através de análises *in situ* das áreas, onde, posteriormente, foram coletados, com o receptor GPS, pontos de amostras em locais de cafeeiros infectados e sadios, i.e., amostras georreferenciadas das classes de feições.

Foram adquiridas imagens Sentinel 2 tomadas em data próxima ao dia da coleta das amostras, a saber, dia 01 março de 2018, em conjunto com os dados de navegação do sensor. Antes do processamento digital das imagens, transformou-se tais produtos do formato JPEG2000 para o formato *Tagged Image File Format* (TIFF) no software SNAP para que se compatibilizasse os arquivos com o que demanda o software de processamento utilizado neste estudo.

Na sequência, as bandas de mesma resolução espacial foram anexadas, no software ENVI pela ferramenta *staging layer*, formando um conjunto de imagens de resolução espacial de 10 metros (azul, verde, vermelho e IVP) e outro de resolução espacial de 20 metros (vermelho limítrofe 1, 2, 3 e 4 e SWIR 1 e 2). Visto que as imagens são disponibilizadas em um nível de processamento “Level-1C”, i.e., têm a sua refletância calculada ao topo da atmosfera (TOA), não houve a necessidade de calibração radiométrica das cenas (ESA, 2018). Todavia, é importante destacar que as imagens adquiridas não são tratadas para os efeitos da absorção e do espalhamento da radiação eletromagnética (REM).

Como a presença da atmosfera entre o satélite e a superfície terrestre ocasiona diversos efeitos indesejados nas imagens de satélites, como, por exemplo, a diminuição dos valores entre superfícies adjacentes e alteração do brilho de cada ponto na imagem (ZULLO, 1994), buscou-se tratar tais incoerências. Segundo Ponzoni et al. (2007), uma das formas de minimizar os efeitos da atmosfera é a aplicação de modelos de correção atmosférica. A conversão de números digitais de uma imagem em parâmetros físicos é um importante processo que possibilita a caracterização espectral de objetos e utilização de operações numéricas entre bandas espectrais (SHOWENGERDT, 2006).

Dessa forma, para realizar a correção atmosférica das imagens no software ENVI, foi necessário informar os valores dos comprimentos de onda médios de cada banda utilizada e a conversão para o formato *Band Inteleaved by Line* (BIL). Em seguida, utilizou-se o módulo de correção *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH) baseado no modelo atmosférico MODTRAN 4 proposto por Kaufman (1997). Vale ressaltar que o FLAASH é um do sofisticado modelo de transferência radiativa e, trata-se de uma função que está no código de transferência radiativa MODTRAN4+. Sua capacidade para correção atmosférica é elevada, tanto nas imagens multiespectrais quanto hiperespectrais, possibilitando correção de fechos indesejados desencadeados pela interação da REM com o vapor d'água, oxigênio, dióxido de carbono, metano, ozônio e aerossol (RUDJORD; TRIER, 2012). Além disso, a correção atmosférica no módulo FLAASH depende do fornecimento de parâmetros de navegação do sensor no momento de tomada da cena. Tais parâmetros (e.g., hora e data de obtenção da cena, altitude, fator de escala, modelo atmosférico, modelo aerossol, absorção de água) foram coletados no arquivo de navegação da imagem. Vale ressaltar que, através de testes empíricos, o parâmetro "fator de escala" satisfatório foi distinto para cada resolução espacial trabalhada: fator de escala 100 para as bandas de resolução espacial de 10 e fator de escala 200 para as bandas de resolução espacial de 20 metros.

Após a aplicação da correção atmosférica obteve-se, como resultado, a reflectância de superfície, i.e., assume-se que os FRHC (Fator de Reflectância Hemisférico Cônico) resultantes se referem aos estimadores da Reflectância Hemisférica Cônica dos alvos presentes na superfície terrestre, sendo possível, então, a caracterização espectral dos mesmos, conforme salienta Showendgert (2006).

Depois de obter as imagens corrigidas, a partir das bandas vermelho e IVP, foi gerado o índice de vegetação *Normalized Difference Vegetation Index* (NDVI), o qual é tradicionalmente utilizado na condução de diferentes tipos de análises sobre as condições da vegetação, nas mais diversas escalas de uma determinada região ou plantação. Rousse et al. (1973) normalizaram a razão simples para o intervalo de -1 a +1 propondo o índice NDVI. Para alvos terrestres os valores do NDVI variam entre 0 e 0,8, aproximadamente. A normalização é feita por meio da equação 1:

$$NDVI = \frac{(\rho_{IVP} - \rho_V)}{(\rho_{IVP} + \rho_V)} \quad (1)$$

Onde ρ_{IVP} é o FRHC no IVP e ρ_V é o FRHC no vermelho. O cálculo do NDVI, resultou em uma nova imagem. Foi realizado no software ENVI por meio da ferramenta *NDVI calculation*. A imagem gerada com o NDVI foi anexada as bandas de resolução espacial de 10 metros com o objetivo de otimizar o processo de classificação.

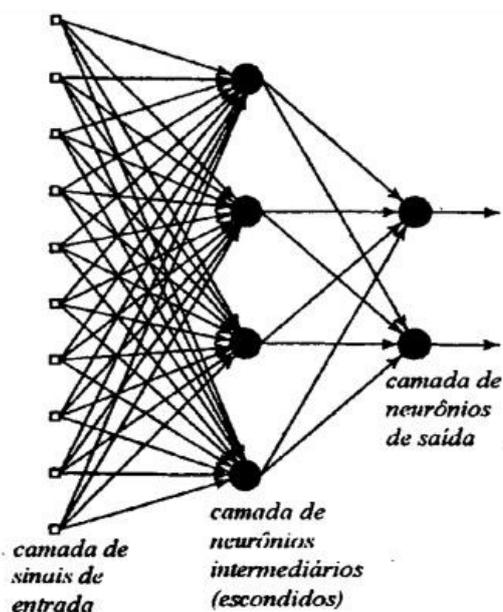
Para a identificação de quais bandas e combinações seriam mais adequadas para a entrada da classificação de imagem, foi realizada uma análise do comportamento espectral das classes que gerou um gráfico de caracterização multiespectral. Para isto, em ambas as áreas, foi calculada a média da

reflectância correspondente em cada banda, a partir de 25 pontos de amostras de cada uma das três classes predominantes, sendo elas: plantas de café infectado por nematoides, plantas saudias e solo exposto. Esses pontos foram definidos considerando-se a distribuição regular por toda a área de estudo, onde se verificou, visualmente, sintomas das ocorrências dos fitopatógenos na vegetação.

A classificação das imagens foi realizada no software ENVI, do módulo de classificação supervisionada, utilizando os parâmetros padrões de classificação por Redes Neurais Artificiais (RNA). Embora outros classificadores supervisionados e não supervisionados sejam capazes de discriminar áreas infestadas por nematoides em diversas culturas conforme verificado por Martins e Galo (2014) e (2017), as RNAs têm sido aplicadas com sucesso no reconhecimento de padrões de imagens de satélite. Uma das principais vantagens das redes neurais é a possibilidade de manipulação eficiente de grandes quantidades de dados. Ademais, destaque tem sido dado às soluções que usam RNAs para classificação de imagens, por conta de, diferentemente da estatística paramétrica tradicional que pressupõe que as classes informacionais apresentam distribuição normal, as classificações via RNAs não assumem nenhuma distribuição (CHAGAS, 2008). Na literatura, os resultados alcançados sugerem que as redes neurais podem ser robustas quando dados espectrais são indistintos ou esparsos e que as redes são capazes de gerar produtos mais acurados, do que aqueles proporcionados pelos métodos que utilizam a estatística convencional para o reconhecimento de padrões (CHAGAS, 2008).

A Figura 3 ilustra a estrutura básica de uma RNA. As entradas da rede representam a informação existente. Elas alimentam a primeira camada de neurônios que através do cálculo executado pela aplicação da função de transferência, geram repostas que alimentam a camada seguinte, e assim sucessivamente até atingirem a camada de saída.

Figura 3 – Estrutura Básica de uma RNA



Fonte: Nishida (1998).

O número de neurônios e camadas em uma dada estrutura é função do problema a ser resolvido. Em um problema de classificação de dados, a camada de saída, pode representar o número de classes para as quais os padrões podem ser designados. Para a classificação de imagens deste trabalho, os padrões de entrada foram localizados em áreas onde se constatou a existência de três classes, “planta sadia”, “planta infectada” e “solo exposto”, ou seja, três neurônios de saída foram necessários.

Neste trabalho a RNA aplicada foi do tipo *feed-forward* em camadas, ou seja, admite que os sinais calculados apenas passem adiante na rede sem retorno. O algoritmo utilizado foi o padrão supervisionado *backpropagation*, o qual, otimiza os pesos para que a rede neural possa aprender a mapear corretamente as entradas para as saídas (SOLUTIONS, 2018). Adicionalmente, é possível selecionar o número de camadas ocultas a serem usadas neste processo, bem como escolher entre uma função de ativação logística ou hiperbólica. A aprendizagem ocorreu ajustando-se os pesos no nó para minimizar a diferença entre a ativação do nó de saída e a saída. O erro é retro propagado pela rede e o ajuste de peso foi feito usando um método recursivo (SOLUTIONS, 2018). Para as classificações das três combinações de imagem foram utilizadas três classes para classificação por RNAs: (1) cafeeiro sadio, (2) cafeeiro infectado e (3) solo exposto. Utilizou-se, ainda, a função de ativação logística, com parâmetros de 0,9 para contribuição do limiar de formação; 0,2 para taxa de treinamento; 0,9 momento de treino; e 0,1 para treinamento dos critérios de saída do Erro Médio Quadrático. O número de camadas ocultas foi igual a 1 e 1000 iterações de treinamento. Vale ressaltar que o treinamento da classificação de imagem foi feito por ROIs (*region of interest*) do tipo polígono, ou seja, considera as classes como reboleiras homogêneas.

No software ArcGis foram gerados os mapas temáticos de infecção por nematoides resultantes do processo de classificação das imagens multiespectrais Sentinel 2. A acurácia da classificação foi avaliada pela matriz de confusão com cálculo do coeficiente de estatística *kappa* e a acurácia global, gerados pelo software ENVI, na seção *post classification*. Para esta análise, foi considerada a geometria de distribuição dos pontos de amostragem no terreno, onde se verificou, visualmente, áreas com sintomas da ocorrência dos fitoparasitas na vegetação. Neste caso, a matriz de confusão representa a qualidade obtida de uma classificação digital de imagem, sendo expressa por meio da correlação de informações dos dados de referência (compreendido como verdadeiro) com os dados classificados. Os dados obtidos *in situ* foram utilizados como dados de referência terrestre para a entrada na matriz de confusão (verificação da acurácia), sendo que, esta coleta de campo, a classe vegetação sadia resultou em 21 pontos, a classe infectada 17 pontos e a classe solo 10 pontos para esta validação.

O coeficiente *Kappa* e a acurácia são índices que retratam o grau de concordância dos dados, gerando um aspecto de confiabilidade e precisão dos dados classificados, e quanto mais próximos de 1 e 100%, respectivamente, mais concordâncias os dados apresentam (LANDIS e Koch, 1977). Os autores Landis e Koch (1977) sugerem os seguintes valores e suas respectivas classes (Tabela 2) para interpretar o valor de *Kappa*.

Tabela 2 – Interpretação do valor Kappa

Kappa	Interpretação
$k < 0$	insignificante
$0 < K < 0,2$	fraca
$0,21 < K < 0,4$	razoável
$0,41 < K < 0,6$	moderada
$0,61 < K < 0,8$	forte
$0,81 < K < 1$	quase perfeita

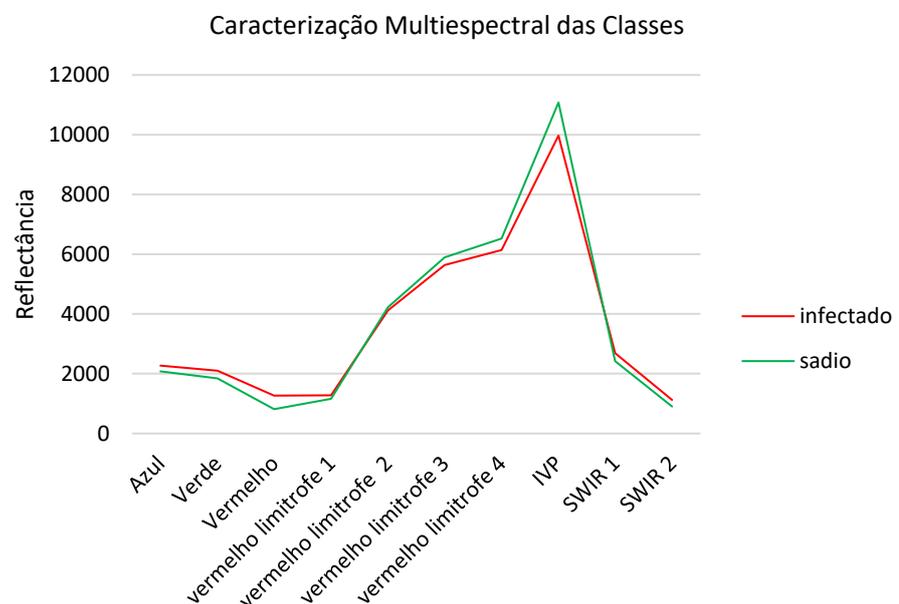
Fonte: Adaptada de Landis e Koch (1977).

A partir da matriz de confusão pode-se avaliar uma série de medidas estatísticas que concluem o processo de validação da classificação de imagem. Dessa forma, nesta pesquisa realizamos, também, uma análise rigorosa desta fonte, levando-se em consideração os valores nas células marginais da matriz, como sendo os erros de comissão (falsos positivos) e omissão (falsos negativos).

RESULTADOS E DISCUSSÃO

A figura 4 apresenta o comportamento espectral para a cultura sadia (verde) e a infectada por nematoides (vermelho) considerando as imagens multiespectrais do satélite Sentinel 2.

Figura 4 – Caracterização Multiespectral das Classes da Área de Estudo



Fonte: Autoria Própria (2018).

Observa-se que há uma forte associação entre a vegetação sadia e infectada, nos intervalos dos comprimentos de onda do espectro visível (Figura 4), sendo que, os maiores valores relacionam-se com as plantas infectadas. Com efeito, para a cultura infectada, os maiores valores nas bandas do azul e do vermelho podem estar associados a desarranjos nutricionais causados pela clorofila a e b e,

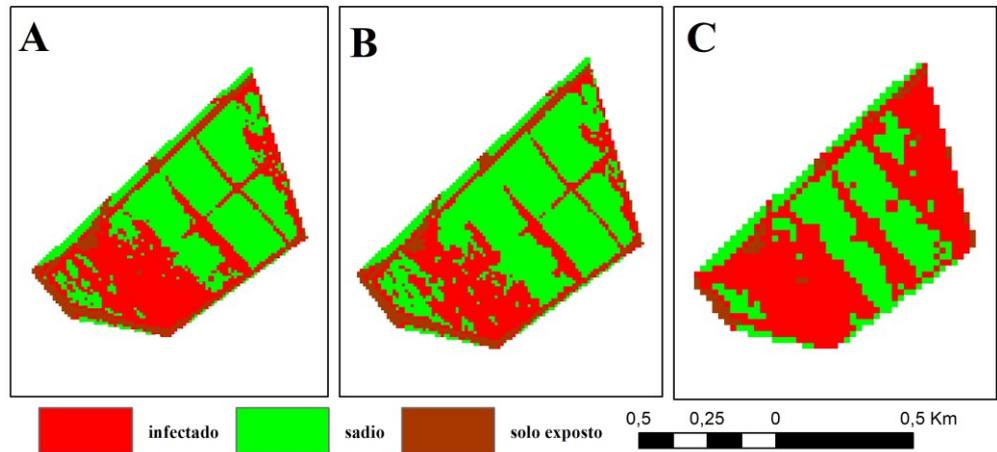
consequentemente, no vigor da planta (JENSEN, 2009). Esta mesma constatação é evidenciada em Martins e Galo (2017), pesquisadores que atribuíram esta condição ao próprio estado fitossanitário da planta infectada por nematoides. Neste caso, Martins e Galo (2017) indicam que, visualmente, as folhas apresentam-se cloróticas e geometricamente semelhante às folhas da planta sadia.

As maiores discrepâncias entre as classes de sanidade passam a ser evidenciadas a partir do intervalo vermelho limítrofe 3 até o intervalo do infravermelho próximo, similarmente aos estudos de Martins e Galo (2013), estudo no qual se constatou que a maior discriminação entre as classes multiespectrais, quando se estuda vegetação, ocorreu na banda do infravermelho próximo (IVP), intervalo espectral mais propício a aplicações agrícolas (JENSEN,2009). A grande discrepância na banda do IVP foi similar ao que verificaram Lipper et al. (2015), quando estudaram, o comportamento espectral de folhas de *E. globulus* atacadas por *Mycosphaerella* spp., nas regiões do visível e do infravermelho próximo. Neste caso específico, os resultados demonstram diferenças no comportamento espectral das folhas de *Eucalyptus globulus* nas duas regiões do espectro eletromagnético avaliadas. Boechat et al (2014), com o estudo de detecção do mofo-branco no feijoeiro, utilizando-se de características espectrais, também, obtiveram como resultado a redução da reflectância na região do IVP, o que foi causada pela infecção dos tecidos das plantas por *S.sclerotiorum* e influenciou no resultado da resposta espectral das plantas.

Com relação ao comportamento espectral das classes (Figura 4), pode-se observar que nas bandas SWIR (infravermelho de ondas curtas), indicadas para avaliação do comportamento hídrico da vegetação, as plantas infectadas por nematoides apresentam maior resposta espectral do que as plantas sadias, Jensen (2009) afirma que este é um comportamento característico de culturas com estresse hídrico causado por patógenos.

A figura 5 apresenta os mapas temáticos de infecção gerados a partir do processo de classificação por redes neurais com a junção das bandas de mesma resolução espacial. Tais soluções são aquelas que se apresentaram mais adequadas para detecção de infecção na cultura cafeeira, i.e., as bandas, vermelho, IVP e vermelho limítrofe 3 e 4, foram as bandas que apresentaram maior discrepância entre as classes de cafeeiro infectado e cafeeiro sadio.

Figura 5 – Resultados da Classificação por RNA, (A) vermelho e infravermelho próximo, (B) vermelho, infravermelho próximo e NDVI e (C) vermelho limítrofe 3 e vermelho limítrofe 4



Fonte: Autoria Própria (2018).

É possível notar que as classificações (Figura 5 A e B) resultantes das bandas do visível e do NDVI, provenientes das bandas de resolução espacial de 10 metros, foram capazes de discriminar as áreas infestadas das saudas com uma resolução espacial relativamente alta. O mesmo ocorre para a classificação proveniente das combinações das bandas do vermelho limítrofe, porém, neste caso, a detecção de áreas infestadas foi possível dado o potencial do intervalo do vermelho limítrofe, visto que, de acordo com Jensen (2009) este intervalo do espectro é o mais adequado para discriminar áreas com problemas de sanidade.

As plantas com alto grau de infecção por *M. paranaensis* normalmente apresentam desfolhamento, e, conseqüentemente, expõem o solo. Por esta razão, nota-se que nas três classificações (Figura 5 A, B e C), ocorreu uma confusão do classificador quando se atribuiu à classe solo exposto áreas pertencentes à classe de plantas infectadas por nematoides. Esta confusão também ocorreu quando o classificador atribuiu a condição de áreas de solo exposto à classe de cafeeiro infectado, visto que os locais onde deveriam ser bordas dos talhões foram classificados como infecção por nematoides.

Nos mapas A e B da figura 5, observa-se que os resultados das classificações foram semelhantes, com uma pequena diferença no tamanho das classes de informação das plantas infectadas, sendo que, para classificação apoiada pelo índice de vegetação NDVI a área foi relativamente menor. A classificação com incremento do índice NDVI pode prover uma maior qualidade na discriminação entre classes de sanidade das plantas, uma vez que, o NDVI é utilizado para construir perfis sazonais e temporais das atividades da vegetação, permitindo comparações interanuais desses perfis.

O perfil temporal do NDVI tem sido utilizado para detectar atividades sazonais e fenológicas das folhas e períodos de senescência (Ponzoni et al., 2007). Martins e Galo (2013) detectaram nematoides e *Migdolus fryanus* em cultura canaveira a partir de imagens multiespectrais Rapideye e ressaltaram que, nas classificações aplicadas aos índices de vegetação, a combinação do EVI com a banda espectral do vermelho limítrofe representou melhor a configuração espacial de talhões e carreadores associada às áreas cultivadas com cana-de-

açúcar, mesmo que o grau de coincidência entre os pontos verificados em campo e as classes rotuladas como nematoides ou *Migdolus fryanus* tenha sido igual ou inferior a 70%. Similarmente, na presente pesquisa, uma vez que o uso do índice de vegetação NDVI resultou em mudanças significativas para a classificação e posterior detecção de pragas. Isso é possível observar, pois, as imagens de resolução espacial de 10 metros combinadas com o NDVI, apresentaram diferenças consideráveis e mais realistas do que a classificação sem a presença do NDVI.

Na classificação usando a combinação de bandas do vermelho limítrofe é possível notar um exagero na estimativa de áreas infestadas por nematoides em relação às demais classificações. Isto ocorre devido ao fato das bandas do vermelho limítrofe apresentarem uma resolução espacial inferior, mesmo tendo maior poder de discriminação de áreas infestadas.

A Tabela 3 apresenta a matriz de confusão para as classificações, índice *Kappa*, acurácia global e os erros de comissão e omissão.

Tabela 3 – Matrizes de Confusão

vermelho e infravermelho próximo				
Amostras Verdadeiras				
Classificação	Planta Sadia	Planta Infectada	Solo Exposto	Total
Planta Sadia	21	1	0	22
Planta Infectada	0	16	0	16
Solo Exposto	0	0	10	10
Total	21	17	10	48
Índice Kappa:0,967				
Acurácia:97,917%				
Classe	Erro Comissão	Erro Omissão		
Planta Sadia	0,045	0,000		
Planta Infectada	0,000	0,059		
vermelho, infravermelho próximo e NDVI				
Amostras Verdadeiras				
Classificação	Planta Sadia	Planta Infectada	Solo Exposto	Total
Planta Sadia	21	3	0	24
Planta Infectada	0	14	0	14
Solo Exposto	0	0	10	10
Total	21	17	10	48
Índice Kappa:0,901				
Acurácia:93,750%				
Classe	Erro Comissão	Erro Omissão		
Planta Sadia	0,125	0,000		
Planta Infectada	0,000	0,176		
vermelho limítrofe 3 e vermelho limítrofe 4				
Amostras Verdadeiras				
Classificação	Planta Sadia	Planta Infectada	Solo Exposto	Total
Planta Sadia	9	0	0	9
Planta Infectada	12	17	2	31
Solo Exposto	0	0	8	8
Total	21	17	10	48
Índice Kappa:0,554				
Acurácia:70,833%				
Classe	Erro Comissão	Erro Omissão		
Planta Sadia	0,000	0,571		
Planta Infectada	0,452	0,000		

Fonte: autoria própria (2018).

Analisando a tabela 3, pode-se perceber que nas combinações vermelho e IVP e vermelho, IVP e NDVI ocorreu confusão do classificador somente na classe planta infectada quando se atribuiu *pixels* à classe planta sadia. Ambas combinações, apresentaram índice Kappa acima de 0,9 e acurácia superior 90%, assim, de acordo com Landis e Koch (1997), estas classificações podem ser consideradas como quase perfeitas.

Na combinação das bandas do vermelho limítrofe, a confusão do classificador ocorreu quando 14 *pixels* foram atribuídos à classe planta infectada, sendo que 12 destes pertenciam à classe planta sadia e 2 à classe solo exposto. Esta situação, gerou um índice Kappa de 0,554, i.e., moderado, de acordo com Landis e Koch (1997). Entretanto, apesar desta confusão do classificador ainda foi possível mapear as classes com uma acurácia acima de 70%.

A partir dos erros de omissão e comissão apresentados na Tabela 3, pode-se perceber que as classificações feitas a partir das combinações de bandas de maior resolução espacial apresentaram valores de erros de comissão e omissão, inferiores a 0,18, sendo que, na classe “planta sadia” não houve erro de omissão e na classe de “planta infectada” não houve erro de comissão. Adicionalmente, a combinação vermelha e IVP apresentou erros inferiores a 0,06, o que pode ser considerado um bom resultado visto que é um valor de erro praticamente nulo.

CONCLUSÃO

Neste estudo constatou-se que é possível mapear com imagens multiespectrais Sentinel 2, com acurácia superior a 70%, áreas de cafeeiro em produção infestadas por *M. paranaenses*. As imagens Sentinel 2 apresentaram potencial satisfatório para a aplicação na detecção de nematoides, principalmente as bandas de resolução espacial de 10 metros quando combinadas com o índice de vegetação NDVI. Estas combinações realizadas configuraram uma classificação de alto nível, ou seja, apresentaram resultados mais próximos da realidade com uma avaliação estatística satisfatória.

As bandas do vermelho limítrofe apresentaram alto potencial para discriminação de áreas infestadas, mesmo sendo inferiores em relação à resolução espacial visto que, conseguiram mapear com boa acurácia e garantindo erros relativamente pequenos.

Dado que a discriminação entre classes de informação foi realizada considerando uma combinação de atributos espectrais e índices de vegetação, com o intuito de aumentar a acurácia do mapeamento, sugere-se para trabalhos futuros, considerar no processo de classificação de imagens por redes neurais, a adição de variáveis extra-imagem, ou seja, dados geomorfológicos: informação altimétrica e variáveis de solo (porosidade, penetrabilidade e resistência), e variáveis agrícolas: índice de área foliar, teor de clorofila e biomassa.

Potential of Sentinel Multispectral Images in the Detection of Nematodes in Coffee Culture

ABSTRACT

In this paper we have evaluated the potential of using free multispectral images for identifying nematode infection in a coffee crop. First, we have adopted a study area within a known condition of the spatial distribution of Nematode infection (*N. paranaenses*) on the coffee crop. Secondly, we analyzed the variation of spectral response of infected and non-infected coffee trees, on different bands of the Sentinel 2 satellite. As hypothesis we expected that healthy trees would respond differently of those non-healthy. Due this first analysis, we have detected bands whose variation on the reflectance could aid us on the image classification process. Thus, we detected those variations, while observing the Red, NIR, Red Edge 3-4 bands. In the next step, we have made the image classification (neural network) by applying different combinations of images sources, considering the results from the previous step, plus an image representing the NDVI index. The combination of Red, NIR, and NDVI bands as classification input gave us the best result when compared to the other combination. This combination allowed us to detect Nematode infection areas, and to perform the image classification with 97.91% of accuracy. Therefore, we have demonstrated the positive potential of using free images from the Sentinel 2 for identifying Nematode infections in coffee crops. This is a remarkable result, once we have produced an innovative, low-cost and confident solution.

KEYWORDS: Multispectral images. Nematoids. Coffee.

REFERÊNCIAS

AGENCIA ESPACIAL EUROPEIA (ESA). Guia do Usuário Sentinel 2. 2018. Disponível em: <<https://earth.esa.int/web/sentinel/user-guides/sentinel-2-msi/product-types/level-1c>>. Acesso em: ago. 2018.

BOECHAT, Lorena Temponi et al. Detecção do mofo-branco no feijoeiro, utilizando características espectrais. **Revista Ceres**, Viçosa, v. 61, n. 6, p.907-915, dez. 2014. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0034-737x201461060004>.

CAMPOS, V.p. et al. Doenças Causadas por Nematoides no Cafeeiro. Controle de Doenças de Plantas: Grandes Culturas, Viçosa, v. 1, p.141-170, mar. 1997.

CHAGAS, César S.; VIEIRA, Carlos A. O.; FERNANDES FILHO, Elpídio I. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 3, n. 13, p.319-327, 29 out. 2008.

CIBULA, W. G.; CARTER, G. A. Identification of a far-red reflectance response to Ectomycorrhizae in Slash Pine. **International Journal of Remote Sensing**, e.13, c.5, p.925-932, 1992.

CONAB. **1º Levantamento da Safra de Café de 2018**. 2018. Disponível em:<http://www.sapc.embrapa.br/arquivos/consorcio/levantamento/conab_safra2018_n1.pdf>. Acesso em jul.2018.

EMBRAPA. **Estudos socioeconômicos e ambientais. 2018**. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/31412007/produtividade-media-da-cafeicultura-brasileira-em-2018-devera-ser-a-maior-ja-registrada-com-2947-sacas-por-hectare>>. Acesso em jul.2018.

IAC. **A luta contra a doença causada pelos nematoides parasitos do café**, Campinas, 2007.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução da 2ª ed. por (pesquisadores do INPE): José Carlos N. Epiphanyo (coordenador); Antonio R. Formaggio; Athos R. Santos; Bernardo F. T. Rudorff; Cláudia M. Almeida; Lênio S. Galvão. São José dos Campos: Parêntese. 672 p, 2009.

LANDIS, J. Richard; KOCH, Gary G.. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, [s.l.], v. 33, n. 1, p.159-174, mar. 1977. JSTOR. <http://dx.doi.org/10.2307/2529310>.

LEMES, Emame Miranda. **Sensoriamento remoto para detecção de seringais infestados por *Meloidogyne exigua***. 2017. 68 f. Tese (Doutorado em Agronomia) - Universidade Federal de Uberlândia, Uberlândia, 2017.

LIPPERT, Diogo Belmonte et al. **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*, Santa Maria, v. 25, n. 1, mar. 2015. <http://dx.doi.org/10.1590/1980-509820152505211>.

MARTINS, George Deroco. **CARACTERIZAÇÃO ESPECTRAL E ESPACIAL DE ÁREAS INFESTADAS POR NEMATÓIDES E MIGDOLUS FRYANUS EM CULTURA CANAVIEIRA.** 115 f. Dissertação (Mestrado) - Curso de Ciências Cartográficas, Unesp, Presidente Prudente, 2013.

MARTINS, George Deroco; GALO, Maria de Lourdes Bueno Trindade. Detecção de áreas infestadas por nematoides e *Migdolus fryanus* em cultura canavieira a partir de imagens multiespectrais Rapideye. *Revista Brasileira de Cartografia*, Brasília, v. 2, n. 66, p.285-301, 01 jun. 2014.

MARTINS, George Deroco; GALO, Maria de Lourdes Bueno Trindade. **Caracterização hiperespectral in situ do cafeeiro infectado por nematoides.** Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015.

MARTINS, George Deroco; GALO, Maria de Lourdes Bueno Trindade; VIEIRA, Bruno Sergio. Detecting and Mapping Root-Knot Nematode Infection in Coffee Crop Using Remote Sensing Measurements. *Ieee Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, [s.l.], v. 10, n. 12, p.5395-5403, dez. 2017. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/jstars.2017.2737618>.

MAY, Gisele Carla. **Análise das alterações do uso e cobertura do solo no município de Centenário-RS com auxílio do sensoriamento remoto, no período de 1995-2014.** 2017. 62 f. Tese - Curso de Geografia, Universidade Federal da Fronteira Sul, Centenário-rs, 2017.

OLIVEIRA, Gildriano Soares de. **Produtividade de biomassa de cana-de-açúcar em função dos índices de vegetação utilizando técnicas de sensoriamento remoto.** 2015. vii, 65 p. Dissertação (mestrado) - Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal, 2015. Disponível em: <http://hdl.handle.net/11449/136733>.

PONZONI, F.J.; SHIMABUKURO, Y.E. **Sensoriamento Remoto no Estudo da Vegetação.** São José dos Campos, SP. Editor Parêntese, 144p. 2007.

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

RUDJORD, Ø.; TRIER, Ø. D. **Evaluation of FLAASH atmospheric correction.** Norsk Regnesentral, SAMBA/10/12, 2012.

SBN. **Sociedade Brasileira de Nematologia - Nemas de Galhas**. 2016. Disponível em: <<http://nematologia.com.br/category/acesso-mini-aulas/meloidogyne-spp/>>. Acesso em: 17 jul. 2018.

SCHOWENGERDT, R. A. **Remote Sensing: models and methods for image processing**. V.3. London: Academic Press, 522p., 2006.

SCHULTZ, Bruno; IMMITZER, Markus; FORMAGGIO, Antonio Roberto. Self-guided segmentation and classification of multi-temporal Landsat 8 images for crop type mapping in Southeastern Brazil. **Multidisciplinary Digital Publishing Institute**, Jaguariúna -sp, v. 7, n. 11, p.14482-14508, 30 out. 2015.

SOLUTIONS, Harris Geospatial. **Neural Net**. Disponível em: <<https://www.harrisgeospatial.com/docs/NeuralNet.html>>. Acesso em: 17 jul. 2018.

SOUZA, S.E. et al. **Levantamento preliminar de Meloidogyne em cafeeiros do Estado da Bahia Planalto de Vitória da Conquista e Chapada Diamantina**. In: Simpósio de Pesquisa dos Cafés do Brasil, I, Poços de Caldas (MG), p. 167-170, 2000.

ZULLO, J. **Correção Atmosférica de Imagens de Satélite e Aplicações**. 1994. 190 p. Tese (Doutorado em Engenharia Elétrica) – Universidade de Campinas, Campinas. 1994.

Recebido: 16 ago. 2018

Aprovado: 10 jun. 2019

DOI: 10.3895/rbgeo.v7n2.8701

Como citar: XAVIER, L. C. M.; JUNIOR, C. A. M. A.; MARTINS, G. D.; BRAVO, J. V. M.; VIEIRA, B. S.. Potencial de Imagens Multiespectrais Sentinel 2 na Detecção de Nematoides na Cultura Cafeeira. **R. bras. Geom.**, Curitiba, v. 7, n. 2, p. 095-114, abr/jun. 2019. Disponível em: <<https://periodicos.utfpr.edu.br/rbgeo>>. Acesso em: XXX.

Correspondência:

Laura Cristina Moura Xavier
km 1, LMG-746, CEP 38500-000, Monte Carmelo, Minas Gerais, Brasil

Direito autoral: Este artigo está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

