

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
INSTITUTO DE CIÊNCIAS AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

FAUSTO ANTÔNIO DOMINGOS JÚNIOR

**IDENTIFICAÇÃO APRIMORADA DE SERINGAIS INFESTADOS POR
FITONEMATOIDES NO MUNICÍPIO DE PRATA, MG, POR
SENSORIAMENTO REMOTO**

UBERLÂNDIA
MINAS GERAIS – BRASIL
2020

FAUSTO ANTÔNIO DOMINGOS JÚNIOR

**IDENTIFICAÇÃO APRIMORADA DE SERINGAIS INFESTADOS POR
FITONEMATOIDES NO MUNICÍPIO DE PRATA, MG, POR
SENSORIAMENTO REMOTO**

Tese apresentada à Universidade Federal de Uberlândia, como parte das exigências do Programa de Pós-graduação em Agronomia – Doutorado, área de concentração em Fitotecnia, para obtenção do título de “Doutor”.

Orientador
Prof. Lísias Coelho, Ph.D.

UBERLÂNDIA
MINAS GERAIS – BRASIL
2020

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

D671i
2020 Domingos Júnior, Fausto Antônio, 1987
Identificação aprimorada de seringais infestados por fitonematoides no município de Prata, MG, por sensoriamento remoto [recurso eletrônico] / Fausto Antônio Domingos Júnior. - 2020.

Orientador: Lísias Coelho.

Tese (Doutorado) - Universidade Federal de Uberlândia, Programa de Pós-Graduação em Agronomia.

Modo de acesso: Internet.

Disponível em: <http://doi.org/10.14393/ufu.te.2021.5007>

Inclui bibliografia.

Inclui ilustrações.

1. Agronomia. I. Coelho, Lísias, 1959, (Orient.). II. Universidade Federal de Uberlândia. Programa de Pós-Graduação em Agronomia. III. Título.

CDU:631

Angela Aparecida Vicentini Tzi Tziboy – CRB-6/947



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agronomia				
Defesa de:	Tese, 017/2020, PPGAGRO				
Data:	Vinte e três de dezembro de dois mil e vinte	Hora de início:	08:00	Hora de encerramento:	11:50
Matrícula do Discente:	11613AGR009				
Nome do Discente:	Fausto Antônio Domingos Júnior				
Título do Trabalho:	Identificação aprimorada de seringais infestados por fitonematoides no município de Prata, MG, por sensoriamento remoto.				
Área de concentração:	Fitotecnia				
Linha de pesquisa:	Controle e Manejo Integrado de Doenças				

Reuniu-se por videoconferência a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agronomia, assim composta: Professores Doutores: Maria Amelia dos Santos - UFU; Ernane Miranda Lemes - Pesquisador; Edson Luiz Furtado - UNESP, Édimo Fernando Alves Moreira - IFTM, Lísias Coelho - UFU orientador do candidato.

Iniciando os trabalhos o presidente da mesa, Dr. Lísias Coelho, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Lísias Coelho, Professor(a) do Magistério Superior**, em 23/12/2020, às 16:08, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Edson Luiz Furtado, Usuário Externo**, em 28/12/2020, às 10:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

Documento assinado eletronicamente por **Maria Amélia dos Santos, Professor(a) do Magistério Superior**, em



28/12/2020, às 11:49, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Édimo Fernando Alves Moreira, Usuário Externo**, em 08/01/2021, às 09:03, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Ernane Miranda Lemes, Usuário Externo**, em 11/01/2021, às 11:55, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2419090** e o código CRC **29044D3E**.

AGRADECIMENTOS

Nenhuma de minhas conquistas podem ser consideradas mérito exclusivo de minhas atitudes. Existem diversas pessoas que de alguma forma contribuíram para que chegasse aonde cheguei.

A princípio, nada teria sido possível se não fossem meus pais, ao mostrarem, por meio do exemplo, a importância e o valor que o conhecimento tem na vida de qualquer ser humano. Sou extremamente grato pela dedicação que tiveram para possibilitar que eu e meu irmão pudéssemos ter a melhor base possível para enfim conseguirmos caminhar por nós mesmos em busca de nossas conquistas. Minha mãe, Cristina, sempre me apoiando, incentivando e dando suporte para que eu vencesse cada etapa. Da mesma forma meu pai, Fausto, que inclusive faz parte da construção desta tese. Ficará guardado pra sempre em minha memória a última viagem que fizemos juntos, em janeiro de 2018, a qual percorremos juntos mais de 600 Km em busca de sementes de seringueira para o meu primeiro experimento do doutorado.

Agradeço à minha esposa, Nathália, que não mede esforços no anseio de me ver concretizando cada um de meus objetivos. Agradeço por toda paciência, principalmente nestes últimos 7 meses, após o nascimento de nosso filho Antônio. Saiba que todo esse esforço é dedicado a vocês. As madrugadas e noites mal dormidas em frente ao computador só eram possíveis porque você estava ao meu lado. Muitas vezes tendo que se virar como mãe e pai, permitindo que eu me dedicasse à conclusão de meu trabalho.

Em meus planos, minha defesa deveria ser no máximo até abril de 2020, pois você, Antônio, só chegaria em maio, conforme realmente aconteceu. Contudo, os planos de defender a tese foram prorrogados devido à pandemia do novo corona vírus. Você nasceu em plena pandemia e o papai não conseguiu viabilizar os últimos resultados para a conclusão da tese. Desta forma, você se tornou meu companheiro de madrugadas. Você chegou e me deu motivos para continuar, me trouxe um propósito e, finalmente, o papai conseguiu.

Agradeço ao meu orientador, Professor Lísias Coelho, pela compreensão nos diversos momentos difíceis que passei durante este período e pela disposição em sempre me ajudar todas as vezes em que o procurei. Sou imensamente agradecido por ter tido a oportunidade de ter sido seu orientado durante o mestrado e o doutorado.

SUMÁRIO

LISTA DE TABELAS	i
LISTA DE FIGURAS	ii
RESUMO	iv
1. INTRODUÇÃO	1
2 REVISÃO DE LITERATURA	4
2.1 Seringueira	4
2.2 Nematoides na seringueira	9
2.3 Índice de Vegetação por Diferença Normalizada - NDVI	16
2.4 Sentinel-2	19
2.5 Google Earth Engine	21
3 MATERIAL E MÉTODOS	24
3.1 Área de estudo	24
3.2 Fluxo de trabalho	27
3.3 Conjuntos de dados e software	29
3.4 Caracterização dos locais da verdade para treinamento	30
3.5 Determinação do valor médio e desvio padrão	30
3.6 Classificação das imagens por NDVI aprimorado	33
3.7 Caracterização dos locais da verdade para validação	34
3.8 Acurácia e concordância da classificação	37
3.9 Script para automação da metodologia	38
4 RESULTADOS	39
4.1 Análise nematológica	39
4.2 Determinação temporal para ajuste do modelo	44
4.3 Mapa da infestação de nematoides das galhas	46
4.4 Acurácia da classificação	49
5 DISCUSSÃO	51
5.1 Distribuição de nematoides	51
5.2 Série temporal para análise	52
5.3 Diagnóstico de <i>Meloidogyne</i> sp. com NDVI aprimorado	54
5.4 Gestão dos resultados	56
6 CONCLUSÕES	58

REFERÊNCIAS	60
APÊNDICES	77
ANEXOS.....	109

LISTA DE TABELAS

TABELA 1 -	Valores de NDVI para diferentes tipos de coberturas	17
TABELA 2 -	Presença de diferentes espécies de nematoides em amostras de solo e raiz coletadas no município de Prata, MG, no mês de julho de 2020	40
TABELA 3 -	Análise de deviance da distribuição populacional de <i>Meloidogyne</i> sp, e <i>Pratylenchus</i> sp.	43
TABELA 4 -	Comparação de médias entre as populações de <i>Meloidogyne</i> sp. e <i>Pratylenchus</i> sp.	43
TABELA 5 -	Teste de U de Mann-Whitney para os valores médios de NDVI de áreas contaminadas e não contaminadas por <i>Meloidogyne</i> sp.	46
TABELA 6 -	Matriz de confusão construída com as informações obtidas no mapa classificado e as informações da verdade de validação	50

LISTA DE FIGURAS

FIGURA 1.	Características morfológicas comuns de <i>Hevea brasiliensis</i> . 1. Floração ramo, 2 e 5. Estrutura da semente, 3. Folha grande típica com venação óbvia, 4. Frutificação ramo, 6. Folhas jovens típicas com atenuação incomum, 7. Válvula lenhosa de frutificação cápsula, 8. Botão e flor de estaminado, 9. Botão carpelado e flor, 10. Ovário5	5
FIGURA 2.	Padrão perineal de <i>Meloidogyne exigua</i> . A: eletromicrografia de varredura evidenciando as espessas estrias; B-D: fotomicrografia evidenciando o arranjo das estrias. Barra de escala: 25 pm10	10
FIGURA 3.	Fotomicrografias de espécimes de <i>Pratylenchus</i> sp. parasitando <i>Zea mays</i> . A. Corpo completo de fêmea; B, C. região anterior feminina; D: Campo lateral; E, F. região vulvar; G, H. região da cauda. Barra de escala: 10 µm13	13
FIGURA 4.	Fotomicrografias de fêmeas de <i>Aphelenchoides</i> sp. A-C. região anterior do corpo. Nota arranjo diferente de válvula em metacorpus e poro excretor (seta) localizado anterior à margem anterior do anel nervoso; D-F: Espermatecas de diferentes tamanhos e formas mostrando espermatozóides dispostos em uma ou várias fileiras (seta = vulva). Barra de escala: 10 µm15	15
FIGURA 5.	Esquemas de distribuição espacial de pragas: A. regular ou uniforme; B. aleatória ou ao acaso; C. agregada ou contagiosa16	16
FIGURA 6.	Valores de NDVI associados aos aspectos sanitários das plantas.....18	18
FIGURA 7.	Bandas espectrais registradas pelos sensores MSI a bordo dos satélites Sentinel-221	21
FIGURA 8.	Área de trabalho do Google Earth Engine. A. Editor de código em linguagem de programação JavaScript23	23
FIGURA 9.	Mapa de localização e altitude da área de estudo24	24
FIGURA 10.	Precipitação (PREC), evapotranspiração potencial (ETP) e evapotranspiração real (ETR) para o município de Prata25	25
FIGURA 11.	Reposição, deficiência, excedente e retirada hídrica para o município de Prata, MG25	25
FIGURA 12.	Mapa geológico do município de Prata, MG26	26

FIGURA 13.	Mapa de uso e ocupação do solo do município de Prata, MG	27
FIGURA 14.	Fluxograma referente ao fluxo de entradas e saídas dos scripts “Zonal Statistics” e “Classification”	29
FIGURA 15.	Pontos georreferenciados das amostras de solo e raiz para caracterização da verdade terrestre de treinamento	30
FIGURA 16.	Exemplificação da obtenção de valores médios de pixels (10 m x 10 m) obtidos por delimitação em buffer com raio de 10 m. A. Área sem buffer; B. Buffer sobrepondo 4 pixels; C. Buffer sobrepondo 6 pixels; D. Buffer sobrepondo 7 pixels; E. Buffer sobrepondo 8 pixels; F. Buffer sobrepondo 9 pixels	32
FIGURA 17.	Exemplo do empilhamento de imagens binárias de diferentes datas para a geração de um único mapa, também binário	34
FIGURA 18.	Distribuição dos 32 pontos para coleta de amostras de solo e raiz como parâmetro para a verdade terrestre	35
FIGURA 19.	Fisionomias dos seringais de Prata, MG: A. Seringal não contaminado; B. Seringal contaminado; C. Seringal contaminado com seringueiras subdesenvolvidas; D. Seringal contaminado com seringueiras mortas	36
FIGURA 20.	Exemplo de pontos para coleta das amostras da verdade terrestre: A. Limpeza do local para amostragem; B. Retirada de amostra de solo e raiz	37
FIGURA 21.	Nematoides encontrados em amostras de solo e raiz, provenientes de seringais no município de Prata, MG, coletados em julho de 2020...41	41
FIGURA 22.	Nematoides encontrados em amostras de solo e raiz, provenientes de seringais no município de Prata, MG, coletados em julho de 2020...42	42
FIGURA 23.	Perfil do NDVI médio de seringais contaminados e não contaminadas por <i>Meloidogyne</i> sp. no município de Prata, MG	45
FIGURA 24.	Mapa temático com classificação binária discriminando áreas com indício de contaminação por nematoides de galha	48

RESUMO

DOMINGOS JÚNIOR, Fausto Antônio. **Identificação aprimorada de seringais infestados por fitonematoides no município de Prata, MG, por sensoriamento remoto.** 2020. 124 f. Tese (Doutorado em Agronomia) – Universidade Federal de Uberlândia, Uberlândia¹.

A seringueira é uma espécie arbórea de grande importância socioeconômica, por ser a principal fonte de borracha natural do mundo. Com a expansão da heveicultura, produtores têm se deparado com alguns problemas fitossanitários e os nematoides tem se destacado, sendo *Meloidogyne exigua* a espécie de maior relevância devido à alta capacidade de proliferação, ocasionando sintomas de deficiência nutricional, e levando à morte de seringueiras. Desta forma, objetivou-se desenvolver uma metodologia de diagnóstico de seringais infestados por nematoides de galha, em grande escala, aprimorando o NDVI com uma série temporal de imagens mais adequadas disponibilizadas pelo conjunto de satélites Sentinel-2A e 2B. Além disso, realizou-se a amostragem para a determinação da densidade e variedade de nematoides presentes nos seringais. A área de estudo foi o município de Prata, MG, e todos os seringais que já se encontravam com dossel fechado foram delimitados. Para a geração de pontos de treinamento, foram coletadas amostras georreferenciadas de solo e raiz em 2 áreas com histórico de infestação por *M. exigua*, onde realmente foi constatada a presença do patógeno. Por meio da plataforma Google Earth Engine foi elaborado um script para a verificação do comportamento dos valores de NDVI dos seringais de Prata, MG, com intuito de verificar a melhor série temporal a se classificar. Estabelecido o melhor período para aquisição das imagens, partiu-se para a criação do script de classificação. A classificação se baseou nos limites superiores e inferiores dos valores dos pixels, estabelecidos pela média e o desvio padrão dos valores de NDVI observados nos pontos de treinamento. Após a classificação foi realizado o levantamento dos pontos de verdade de campo para validação do mapa classificado e verificação da população de nematoides presentes nas áreas. A metodologia apresentou acurácia de 87,5% e índice Kappa de 0,75. A série temporal de imagens considerada mais adequada para aplicação da metodologia foi do período de janeiro a junho e o mês de outubro. *Pratylenchus* sp. esteve presente em todas as amostras, representando 77,58% da densidade populacional encontrada. Já *Meloidogyne* sp. foi observada em 18 amostras e representou 14,69% da

densidade populacional. Os demais nematoides somados representaram apenas 7,72% da população. Estimou-se que 1.983,44 hectares têm indícios de infestação, correspondendo a 72,57% dos 2.733,06 hectares de seringueira avaliados no município.

Palavras-chave: *Hevea brasiliensis*. Nematóide de galha. Nematóide das lesões. Sentinel-2. Google Earth Engine. Geoprocessamento.

¹Orientador: Lísias Coelho

ABSTRACT

DOMINGOS JÚNIOR, Fausto Antônio. **Improved Identification of rubber tree orchards infested by phytonematodes in the county of Prata, MG, by remote sensing.** 2020. 124 f. Thesis (Doctorate's degree in Agronomy) – Federal University of Uberlândia, Uberlândia¹.

The rubber tree has great socio-economic importance since it is the main source of natural rubber in the world. Due to the expansion of heveiculture, some concern has risen due to phyto-sanitary problems, among which are the nematodes. *Meloidogyne exigua* has been the most important species in rubber tree plantations due to its high proliferation, leading to nutrition deficiency symptoms, and causing plant death. Thus, this study developed a large scale diagnosis method for orchards infested by the root-knot nematode, improving NDVI with a time series of images available by the satellites Sentinel-2A and 2B. Also, field samples were collected to determine nematode population density and diversity in the orchards. The study area was the county of Prata, MG, and all the rubber tree orchards with closed canopies were mapped. Geo-referenced soil and root samples were collected in two areas with confirmed infestation by *M. exigua* to generate training points. A script was generated in the platform Google Earth Engine to confirm the behavior of NDVI values in the orchards in Prata, MG, to select the best time series for classification. Subsequently, the classification script was created. The classification was based on the upper and lower limits of pixel values, established by the average and standard deviation of NDVI values observed in the training points. Field truth points were sampled to validate the classification map and confirmation of nematode density in the orchards. The methodology presented an accuracy of 87.5% and Kappa index of 0.75. The image time series considered as most adequate for this methodology was from January to June, and the month of October. *Pratylenchus* sp. was found in every sample, representing 77.58% of the population density. In contrast, *Meloidogyne* sp. was observed in 18 samples, representing 14.69% of the total population density. All other plant parasite nematodes found in the area represented only 7.72% of the population. It was estimated that 1,983.44 hectares have infestation signs by *M. exigua*, corresponding to 72.57% of the 2,733.06 hectares of rubber tree orchards evaluated in the county.

Keywords: *Hevea brasiliensis*. Root knot nematode. Lesion nematode. Sentinel-2. Google Earth Engine. Geoprocessing.

1 INTRODUÇÃO

A seringueira [*Hevea brasiliensis* (Willd. Ex ADR. De Juss.) Muell Arg.] é uma espécie arbórea de grande importância socioeconômica, caracterizada por ser a principal fonte de borracha natural do mundo (KRISHNAN et al., 2019; ALI et al., 2020). A borracha natural é uma matéria-prima industrial essencial na fabricação de uma vasta gama de produtos, que vai desde utensílios domésticos, materiais escolares e roupas, até pneus de aeronaves e dispositivos médicos. Apesar de inúmeras tentativas do homem de encontrar alternativas, a borracha natural oriunda da seringueira, ainda é insubstituível, sendo a principal fonte do material para a indústria no mundo todo (BROWN et al., 2017).

Nas últimas décadas houve um crescimento significativo na demanda da indústria por borracha natural, o que fez com que as áreas ocupadas por seringais, aumentassem significativamente em todo o mundo (YE, 2018). Somente no sudeste da Ásia continental essas áreas aumentaram em quase 2.500%, passando de aproximadamente 300.000 ha em 1961, para mais de 8 milhões em 2014 (BERTHELOT et al., 2014).

No Brasil a expansão foi igualmente significativa - somente no Estado de São Paulo, o número de árvores de seringueira cresceu de menos de 5 milhões em 1983 para mais de 58 milhões na safra 2019/20 (IEA, 2018; IEA, 2020). Ainda, é previsto que nos próximos anos a demanda por borracha natural continue crescendo em todo o mundo, e para acompanhar tal demanda, é estimado que os seringais ocupem outros 8,5 milhões de hectares até 2024 (WARREN-THOMAS et al., 2015).

Com a expansão dos seringais para novas áreas, tanto no Brasil quanto no mundo, é comum que a heveicultura se depare com uma variedade de problemas fitossanitários, entre eles, está a disseminação de nematoides (PAES-TAKAHASHI et al., 2015). Os nematoides fitoparasitas se alimentam de tecidos vegetais diversos, como flores, caules e folhas, sendo que a maioria das espécies se alimenta de raízes (SIDDIQUE; GRUNDLER, 2018).

Do ponto de vista econômico, as espécies de nematoides de maior importância são aquelas que reduzem a produtividade das culturas, entre as quais, gêneros como *Meloidogyne* e *Pratylenchus* são destacados (DINARDO-MIRANDA et al., 2019). De acordo com Wilcken et al. (2015), dos nematoides que parasitam a seringueira, os de maior importância pertencem aos gêneros *Meloidogyne* e *Pratylenchus*, sendo as

espécies *P. brachyurus*, *M. icognita* e *M. exigua* as mais prejudiciais à cultura. Tais autores ainda citam que, nos seringais brasileiros, *M. exigua* é a espécie de maior relevância devido à alta capacidade de proliferação. Corroborando, Gasparotto et al. (2016) enfatizam que as seringueiras atacadas apresentam sintomas de deficiência nutricional e, independentemente da idade da planta, o nematoide pode levar à morte de seringueiras.

Um dos grandes entraves para o monitoramento e controle de nematoides é o diagnóstico nas extensas áreas dos seringais, por isso, a fim de viabilizar a identificação de áreas contaminadas de forma prática e eficiente, estudos apontam a possibilidade do diagnóstico de seringais infestados por nematoides através de índices espectrais de vegetação, especialmente o *Normalized Difference Vegetation Index* (NDVI), que possibilita avaliar o vigor da planta por meio do sensoriamento remoto (DUARTE et al., 2019; LEMES et al., 2020; PEZZONI FILHO, 2014).

Entretanto, ao ser considerada a possibilidade da aplicação do NDVI no diagnóstico de grandes áreas contaminadas por nematoides em seringais, ainda não se utilizou, para este fim, a programação em script na plataforma do Google Earth Engine (GEE) objetivando o processamento de imagens em séries temporais com empilhamento dos valores de NDVI, o que possibilita o aprimoramento das informações buscadas.

Geralmente, tem-se utilizado nos trabalhos apenas os valores espectrais ou recursos de vetor de mudança espectral em dois perfis de tempo independentes, os quais se mostram insuficientes para atender às necessidades de detecção precisa de variações (HU et al., 2018; ZHOU et al., 2020). Assim sendo, segundo Valle Júnior et al. (2019), é possível aprimorar as respostas obtidas pelo NDVI ao serem levadas em consideração as coincidências de valores de NDVI de imagens de um mesmo local ao longo do tempo, garantindo maior confiabilidade na identificação das áreas de interesse.

A eficiência da utilização do GEE tem sido verificada em diversos estudos em grandes áreas, como o efeito da ocupação do solo nas condições ambientais em bacia hidrográfica (ZURQANI et al., 2018), na avaliação da sustentabilidade do crescimento urbano e serviços ecossistêmicos (LIANG et al., 2020), na caracterização da vegetação de montanhas e as interações com as mudanças climáticas (BIAN et al., 2019).

Com o avanço dos seringais em diferentes regiões do país, é importante que existam ferramentas que permitam observar a expansão destas áreas e também possibilitem indicação de possíveis focos de contaminação por *Meloidogyne* sp., a fim

de se controlar a disseminação deste patógeno. O uso de imagens de satélite faz bem esse papel de monitoramento, contudo, não permite fazer um diagnóstico, ao menos preliminar, de áreas contaminadas por nematoides.

A possibilidade do monitoramento da sanidade dos seringais quanto à presença de nematoides permitiria a tomada de decisão quanto ao melhor manejo antecipadamente. Além disso, possibilitaria o impedimento de registro no RENASEM de propriedades contaminadas como áreas destinadas à produção e comercialização de material de propagação de seringueira.

Assim, diante da necessidade de se identificar áreas infestadas por nematoides, o presente estudo buscou desenvolver um script na plataforma em nuvem no GEE, a partir de séries temporais de imagens Sentinel-2, permitindo o mapeamento automático de grandes áreas infestadas por nematoides na cultura da seringueira.

A hipótese levantada é a de que o uso de uma série temporal de imagens NDVI e a correlação entre a coincidência de parâmetros espectrais indicando a presença de nematoides possam ser utilizados como uma ferramenta de diagnóstico para a determinação de áreas com indício da presença de *Meloidogyne* sp. (nematóide de galha) em seringais no município de Prata, MG.

Para tanto, objetivou-se:

- Desenvolver uma metodologia de diagnóstico de seringais infestados por nematoides de galha, em grande escala, aprimorando o NDVI utilizando a série temporal de imagens mais adequadas disponibilizadas pelo conjunto de satélites Sentinel-2A e 2B;
- Determinar o melhor período da série temporal para a coleta de imagens e geração do mapa com diagnóstico de infestação de seringais por nematoides de galha;
- Verificar a densidade populacional e os gêneros de nematoides presentes no solo e raízes de seringais do município de Prata, MG;
- Validar o nível de eficiência da nova metodologia apresentada para detecção de nematoides de galha em seringais;
- Estimar as áreas de seringais com indícios de contaminação por nematoides de galha no município de Prata, MG.

2 REVISÃO DE LITERATURA

2.1 Seringueira

Seringueira é o nome vulgar da planta pertencente ao gênero *Hevea*, da subfamília Crotonoideae (APG, 2009). O número de espécies reconhecidas contempla formalmente dez espécies dentro de seu gênero. As espécies, listadas em ordem cronológica de identificação são: *H. guianensis*, *H. brasiliensis*, *H. pauciflora*, *H. spruceana*, *H. rigidifolia*, *H. benthamiana*, *H. nitida*, *H. microphylla*, *H. camporum* e *H. camargoana* (PRIYADARSHAN, 2003).

Originária da Amazônia, todas as espécies são consideradas nativas no Brasil, porém, em todos os países nos quais a floresta Amazônica adentra são encontradas espécies de seringueira (WYCHERLEY, 1992). De todas as espécies relatadas, apenas a *H. brasiliensis* é amplamente explorada e cultivada. Contudo, apesar de não ser cultivada, *H. guianensis* ainda é explorada e *H. benthamiana* tem sido utilizada para a produção de híbridos com *H. brasiliensis* (WYCHERLEY, 1992; PRIYADARSHAN, 2003).

A seringueira é uma árvore de caule ereto, quase cilíndrico, chegando a 40 m de altura com raiz principal pivotante e ramificações, casca externa rosada ou marrom escuro. Produz um látex branco e leitoso. Conforme observado na Figura 1, suas folhas são trifolioladas, com pecíolos de 15 a 25 cm de comprimento, apresentando um par de glândulas ou nectários na inserção dos pecíolos. Os folíolos são oblongos ou obovados, de 10 a 15 cm de comprimento por cinco a nove centímetros de largura. O lado superior é verde escuro e brilhante, e o inferior, mais claro e mais opaco (LEÓN, 1987; LORENZI, 2002).




Figura 1. Características morfológicas comuns de *Hevea brasiliensis*. 1. Floração ramo, 2 e 5. Estrutura da semente, 3. Folha grande típica com venação óbvia, 4. Frutificação ramo, 6. Folhas jovens típicas com atenuação incomum, 7. Válvula lenhosa de frutificação cápsula, 8. Botão e flor de estaminado, 9. Botão carpelado e flor, 10. Ovário. (Fonte: SCHULTES, 1987).

A faixa de aptidão climática ótima para a seringueira, que leva em consideração as condições impróprias às epifitias graves do mal-das-folhas, prevê temperatura anual superior a 18°C, temperatura do mês mais frio de 15 a 20°C e deficiência hídrica anual de 1 a 300 mm, o que compreende quase todo território mineiro (ORTOLANI, 1983).

Segundo Haag et al. (1982), em países com umidade e temperaturas amenas (condições favoráveis ao crescimento de fungos causadores de doenças foliares), a uniformidade do índice pluviométrico é fundamental para o estabelecimento de altas produtividades.

Na região Amazônica, de clima megatérmico superúmido, as médias mensais de umidade relativa do ar, acima de 80% nos meses mais secos, predispõem as plantas à ocorrência de doenças. Por outro lado, em regiões onde a média mensal situa-se entre 50 e 65% nos meses mais secos, quando ocorrem a queda e a renovação foliar, tornam-se mínimas as possibilidades de infecção por fungos (KITAMURA, 1989).

Sendo a seringueira uma planta originária do trópico úmido, torna-se susceptível às baixas temperaturas, principalmente nos primeiros anos de implantação. Aos quatro ou cinco anos com porte elevado tem mostrado maior resistência às geadas (ORTOLANI et al., 1982).

Existe uma ligação entre as características hidráulicas e o hábito das folhas da seringueira. Dentro de sua área nativa, a floresta amazônica, a seringueira é uma planta perenifolia semidecídua (LORENZI, 2002), mas torna-se caducifolia em áreas com períodos secos prolongados. O motivo dessa mudança ainda é pouco conhecido, mas estudos sugerem que uma combinação de características hidráulicas, características de troca gasosa e condições hídricas durante a estação seca pode desencadear uma mudança nos hábitos foliares de *H. brasiliensis* em áreas aonde ela foi introduzida (CHEN; CAO, 2015).

Em suas condições originais, a seringueira desenvolve-se em solos predominantemente ácidos e de baixa fertilidade natural, existindo considerável variabilidade nas características físicas e químicas dos solos sob seringueira (KITAMURA, 1989).

Tanto na Malásia como no Brasil, o plantio de seringueira é geralmente relegado aos solos quimicamente pobres que, associados às boas características físicas, têm obtido respostas positivas à aplicação de fertilizantes. Na Malásia, os efeitos da aplicação de nitrogênio, fósforo e potássio são positivos, no sentido de redução do período de imaturidade da seringueira. Nota-se que a seringueira se adapta a diferentes

tipos de solos, desde que haja boas condições físicas, tais como: profundidade mínima de 2 m, bem drenados, de estrutura moderadamente desenvolvida, porosos, permitindo, desse modo, boa aeração e movimento de água através do seu perfil (ORTOLANI, 1982).

Considerada exigente em relação às características físicas e hídricas no solo para conseguir alcançar boas produtividades de látex, que chega a ter 68% de água em sua constituição, a seringueira requer solos profundos, porosos, bem drenados, de textura argilosa e com boa retenção de umidade (CUNHA et al., 2000).

As mudas comerciais de seringueira são clonais. Por meio da enxertia é possível selecionar e, desta forma, garantir que tais mudas apresentarão altos índices de produtividade, além de características que possibilitem o melhor controle fitossanitário (DUARTE, 2007). Os clones são obtidos através da propagação vegetativa de uma mesma planta matriz, o que faz com que os seringais cultivados com o mesmo clone apresentem grande uniformidade, já que possuem a mesma constituição genética (MARQUES et al., 2007).

A enxertia como método para produção de mudas clonais de seringueira foi desenvolvida por Van Helten na Indonésia em 1916, caracterizando o processo de propagação agâmica da seringueira e, através dos anos vem sofrendo sucessivos aprimoramentos visando reduzir o tempo de formação de mudas (LEMOS FILHO, 1991).

Como vantagens desta técnica, além da resistência a doenças, citam-se: escolha mais ampla do material de plantio; maior produção de borracha; maior rendimento do refolhamento que se segue após a dormência de inverno (EMBRATER, 1981).

Para um bom estabelecimento da cultura no momento de seu plantio, é importante escolher o período do ano que garanta água suficiente para promover o pegamento das mudas. O plantio convencional é realizado com 500 plantas ha⁻¹ e um espaçamento que pode variar de 7 a 8 metros, por 2,5 a 3,0 metros, sendo importante realizá-lo todo em nível (MEDRADO et al., 1992).

Dependendo do método de manejo usado, as plantações de seringueira podem ser economicamente sustentáveis por 20 a 30 anos, e um bom manejo de nutrição precisa ser mantido em todos os estágios de seu desenvolvimento para evitar desequilíbrio nutricional e graves danos à produção de látex. Para estabelecer o manejo adequado dos seringais, o conhecimento do solo é essencial, principalmente para cada clone e cada categoria de solo (CUNHA et al., 2000).

Muitos produtores têm optado por fazer uma produção consorciada com a seringueira, para garantir renda enquanto as árvores não entram em sangria, ou mesmo para melhorar o ambiente de desenvolvimento das mudas de seringueira. A intercalação de culturas pode acontecer com diversas plantas, sendo mais interessante iniciar o processo de consórcio já no início da implantação do seringal (FRANSCISCO et al., 2004).

O grande motivo para a exploração da seringueira é a borracha natural, matéria-prima industrial globalmente essencial usada na fabricação de uma vasta gama de produtos desde pneus de aeronaves e veículos a roupas e dispositivos médicos. Apesar de inúmeras tentativas de encontrar plantas alternativas para a produção de borracha natural, a seringueira, *H. brasiliensis*, ainda é insubstituível, a principal fonte comercial para a indústria de borracha natural em todo o mundo (BROWN et al., 2017).

Segundo Alvarenga (2007) com a descoberta, pelos ingleses, da praticidade do látex e, posteriormente, a descoberta do processo de vulcanização, quando as qualidades elásticas da borracha natural foram estabilizadas, deu-se início aos estudos de aclimação da seringueira em regiões fora do seu hábitat.

O fator que costuma afetar a produtividade de uma plantação de seringueira é o clone a ser plantado. A correta seleção de plantas, substrato e clone deve proporcionar altos rendimentos durante os primeiros anos de sangria e permanecer inalterada durante a exploração do látex (MARQUES et al., 2007).

A produção das seringueiras, até então com média de 496 kg ha⁻¹ ano⁻¹ na década de 1920, passou a ter média de 1.600 kg ha⁻¹ ano⁻¹ na década de 1960, até chegar ao patamar de 2.500 kg ha⁻¹ ano⁻¹ nos últimos anos, graças à introdução de clones como PB, RRIM, RRII, BPM e vários outros (GONÇALVES et al., 2002; PRIYADARSHAN, 2017).

De toda produção mundial de borracha natural, 80% encontra-se na mão de pequenos produtores com área de até 4 hectares. Na Índia, 92% das propriedades possuem área média de 0,5 hectare e maior produtividade média de borracha natural do mundo. A grande maioria das regiões do estado de Minas Gerais caracteriza-se por pequenas e médias propriedades, que se constituem como a única fonte de renda dos produtores calcada de mão-de-obra familiar (ALVARENGA, 2007).

Países como a Índia, Malásia, Tailândia, e Indonésia, principais exportadores de borracha, além do Brasil, são os que mais se esforçam no desenvolvimento de clones de alta produção e adaptados às diferentes condições sanitárias e edafoclimáticas

(PRIYADARSHAN, 2003; PRIYADARSHAN, 2017).

2.2 Nematoides na seringueira

Os primeiros levantamentos de forma mais ampla realizados com intuito de identificar os nematoides parasitas de plantas e nematoides de vida livre associados à seringueira foram feitos entre 1971 e 1972 no estado da Bahia, nos quais foram identificados *Meloidogyne* sp., *Pratylenchus brachyurus* (Godfrey) Filipjev & Stekhoven, *Rotylenchulus reniformis* Linford e Oliveira, entre outros, em plantas adultas no campo (SHARMA, LOOF, 1973).

Um dos problemas relacionados à disseminação dos nematoides e outros patógenos pelo Brasil é a produção de mudas diretamente em canteiros no solo ou mesmo a utilização do solo sem tratamento para o preenchimento de recipientes para acomodação das mudas (GONÇALVES, 2010). Como se não bastasse, um agravante observado na cultura da seringueira é a predominância de um único clone na maioria dos seringais do Brasil, o RRIM 600 (SCALLOPI JUNIOR, 2012).

Os nematoides se disseminaram por todas as áreas agricultáveis do Brasil. Isso se deve à sua alta resistência e fácil adaptabilidade às diversidades ambientais que os levam a serem facilmente transportados por máquinas, implementos, pelo homem e até mesmo pelos materiais de propagação, como sementes e mudas, se dispersando e proliferando rapidamente.

Os gêneros *Meloidogyne* e *Pratylenchus* são considerados os mais importantes para a cultura da seringueira; entretanto, outros nematoides também são encontrados habitando seringais (WILCKEN et al., 2015). No gênero *Pratylenchus*, a espécie *P. brachyurus* é a mais importante, enquanto no gênero *Meloidogyne*, as espécies *M. exigua* (Figura 2) e *M. incognita* aparecem como as mais daninhas, entretanto, *M. exigua* é considerada de maior importância devido principalmente à sua disseminação nos seringais brasileiros (GONÇALVES, 2010). Quase todas as espécies de nematoides de galha são especialmente importantes em regiões de agricultura tropicais e subtropicais (LE, 2020).




Figura 2. Padrão perineal de *Meloidogyne exigua* A: eletromicrografia de varredura evidenciando as espessas estrias; B-D: fotomicrografia evidenciando o arranjo das estrias. Barra de escala: 25 μ m. (Fonte: MUNIZ et al., 2009).

Um grande problema que vem afligindo os heveicultores no Brasil tem sido a rápida disseminação do nematoide *Meloidogyne exigua*, principalmente por meio da produção de mudas de seringueira (BERNARDO et al., 2003; PAES-TAKAHASHI et al., 2015; PEZZONI FILHO, 2014; WILCKEN et al., 2015).

Em 1887, Goeldi descreveu os nematoides formadores de galhas (observações de 1878), na antiga Província do Rio de Janeiro, quando foram observadas em raízes de cafeeiro a presença de pequenas e numerosas estruturas denominadas galhas, nas quais ocorriam estruturas císticas que continham ovos elípticos e pequenos animais vermiformes denominados por Goeldi de *M. exigua* (GOELDI, 1892). Já o primeiro relato de parasitismo de nematoide em seringueira foi no Congo Belga, em 1921,

quando foram observados nematoides de galha, *Meloidogyne* spp. (GONÇALVES, 2010).

Os nematoides de galha danificam as raízes das plantas, utilizando seu estilete para penetrar nas paredes celulares e, depois que as células gigantes são formadas, o estilete é usado para absorver os nutrientes dessas células. Eles estimulam as células do parênquima na raiz para transformá-las em células gigantes das quais o nematóide obtém nutrientes ao longo de sua vida (LE, 2020).

Abad et al. (2009) relataram que os nematoides de galha não matam as células nas quais eles se alimentam porque as células gigantes só fornecem nutrientes ao nematóide enquanto estas permanecerem saudáveis. Isso ajuda a explicar por que as plantas infectadas com *Meloidogyne* spp. podem ter crescimento comprometido e produzir pouco, mas geralmente não morrerem. No entanto, fatores abióticos de estresse podem resultar na morte da planta, se esta já estiver enfraquecida devido a um alto nível de infestação de nematoides (LE, 2020). Os sintomas variam porque eles dependem da espécie de nematóide de galha e da idade da planta (VILLAIN et al., 2018).

Os nematoides do gênero *Meloidogyne* tem seu ciclo iniciado com a eclosão dos ovos e a penetração dos juvenis de segundo estágio (J2) na base do cilindro vascular, penetrando pelo córtex vascular da planta (WYSS et al., 1992). No sistema radicular iniciam a formação das galhas, o que leva as plantas a apresentarem diversos sintomas que, ao prejudicarem o desenvolvimento radicular pela sua redução e deformação, diminui a capacidade de absorção de água e nutrientes, causando murcha, desfolha, sintomas de deficiência mineral e conseqüente diminuição no crescimento de toda estrutura da planta, podendo inviabilizar seu cultivo em áreas de alta infestação ao levarem a produtividade a patamares que tornam a produção economicamente insustentável (TIHOHOD, 2000).

Após o gênero *Meloidogyne*, no Brasil, os nematoides do gênero *Pratylenchus*, conhecidos como nematoides das lesões radiculares, são os de maior relevância para agricultura (SANTOS et al., 2015). A espécie *P. brachyurus*, teve grande disseminação em todo território brasileiro devido à sua ampla gama de plantas hospedeiras e é considerada a espécie de nematóide de maior relevância à cultura da soja, devido à sua frequente presença nas lavouras e os danos oriundos de seus hábitos (ALVES, 2015).

Várias espécies de *Pratylenchus* como *P. penetrans*, *P. brachyurus*, *P. coffeae* e *P. vulnus* têm uma ampla distribuição geográfica e podem parasitar uma ampla gama de plantas hospedeiras (CASTILLO, VOVLAS, 2007). Dentro do gênero *Pratylenchus*, 98

espécies foram reconhecidas por Geraert (2013) e posteriormente, outras três espécies adicionais foram descritas (PALOMARES-RIUS et al., 2014; HODDA et al., 2014; WANG et al., 2015), totalizando 101 espécies descritas.

A população de *P. brachyurus* apresenta características morfológicas como a região labial com dois anéis, estilete com saliências amplamente arredondadas, vulva posicionada posteriormente, dentre outras características (Figura 3) (SUBBOTIN et al., 2008).




Figura 3. Fotomicrografias de espécimes de *Pratylenchus* sp.: A. Corpo completo de fêmea; B, C. região anterior feminina; D: Campo lateral; E, F. região vulvar; G, H. região da cauda. Barra de escala: 10 μ m. (Fonte: Adaptado de JANSSEN et al., 2017).

Considerando as variações das condições ambientais e a espécie hospedeira, *Pratylenchus* spp. podem apresentar um ciclo de vida que varia entre 3 a 9 semanas (JONES, FOSU-NYARKO, 2014). Todas as espécies do gênero *Pratylenchus* são endoparasitas migratórios, causando graves danos às raízes do hospedeiro (CASTILLO, VOVLAS, 2007)

As secreções esofagianas tóxicas liberadas e injetadas no sistema radicular por *Pratylenchus* spp. são as responsáveis pelos graves danos que levam à formação de áreas necrosadas, se tornando uma situação ainda pior por se tratar de um parasitismo do tipo migrador, o que leva à abertura de diversas fissuras por todo o sistema radicular, possibilitando a entrada de microrganismos oportunistas ou fitopatogênicos, prejudicando o estabelecimento e desenvolvimento da planta (WEISCHER, BROWN, 2001).

O gênero *Aphelenchoides* é conhecido por ser parasita foliar no arroz, morango, soja e várias outras plantas em diversos países (DE WAELE, 2002; ANON, 2017). Contudo, sua ocorrência em seringueira foi relatada já em 1986, em seringais do estado do Espírito Santo (RASHID et al., 1987), além de ter sido constatado em mudas produzidas por viveiros do estado de São Paulo (PAES-TAKAHASHI et al., 2016).

As novas descrições e estudos morfológicos de *Aphelenchoides* foram baseados principalmente em populações de arroz, por ser mais comum e difundido do que outras culturas. A redescritção mais precisa e ilustrações dos indivíduos das populações de arroz de *Aphelenchoides* foram publicadas por Fortuner (1970). A combinação desses caracteres (Figura 4) tem sido usada como critério para a identificação morfológica de *Aphelenchoides* em todos os estudos subsequentes (OLIVEIRA et al., 2019).




Figura 4. Fotomicrografias de fêmeas de *Aphelenchoides* sp. A-C. região anterior do corpo. Nota arranjo diferente de válvula em metacorpúsculo e poro excretor (seta) localizado anterior à margem anterior do anel nervoso; D-F: Espermatecas de diferentes tamanhos e formas mostrando espermatozoides dispostos em uma ou várias fileiras (seta = vulva). Barra de escala: 10 µm. (Fonte: SUBBOTIN et al., 2020).

Diversos outros nematoides também foram relatados em seringueira, entre os quais estão: *Rotylenchulus* (SHARMA, LOOF, 1973; WILCKEN et al., 2015; PAES-TAKAHASHI et al., 2016), *Helicotylenchus* (FREIRE, 1976; PAES-TAKAHASHI et al., 2016), *Criconemella* (FREIRE, 1976; SHARMA, 1976; WILCKEN et al., 2015), *Rotylenchus* (FREIRE, 1976), *Aphelenchus* (SHARMA, EKhardt, 1979).

Devido à distribuição dos níveis populacionais de nematoides no campo apresentarem forma binomial negativa, ou seja, muitos pontos sem ou com poucos nematoides e poucos pontos com muitos nematoides, a distribuição dos nematoides é considerada do tipo agregada ou contagiosa, tendo sua ocorrência em reboleiras (Figura 5) (GUERREIRO et al., 2012).




Figura 5. Esquemas de distribuição espacial de pragas: **A.** regular ou uniforme; **B.** aleatória ou ao acaso; **C.** agregada ou contagiosa. (Fonte: GUERREIRO et al., 2012).

Todavia, um dos grandes entraves para o monitoramento e controle de nematoides é o seu diagnóstico nas extensas áreas dos seringais. Os sintomas observados acabam surgindo tardiamente, normalmente quando o dossel se fecha. A fim de viabilizar a identificação de áreas contaminadas de forma prática e eficiente, estudos apontam a possibilidade de verificação de seringais infestados pelo nematoide de galha *M. exigua* através de índices espectrais de vegetação, especialmente o índice NDVI (Índice de Vegetação por Diferença Normalizada) (DUARTE et al., 2019; LEMES et al., 2020).

2.3 Índice de Vegetação por Diferença Normalizada - NDVI

O início dos estudos com as combinações fotográficas de infravermelho e vermelho linear para monitorar a vegetação biomassa e estado fisiológico ocorreu no final da década de 1970, quando foi observado que a relação infravermelho / vermelho (índices de vegetação), foram sensíveis à biomassa fotossinteticamente ativa (ROUSE et al., 1974; TUCKER, 1979). O mais conhecido e utilizado desses índices, é o índice de

vegetação de diferença normalizada (NDVI). O NDVI tem sido utilizado como indicador para a fração da radiação fotossinteticamente ativa absorvida pela vegetação (fPAR) e é amplamente utilizado como uma representação da biomassa vegetal e produtividade da vegetação (SANTIN-JANIN et al., 2009; VOGELMANN et al., 2012).

O índice é baseado na observação, que ao se medir os comprimentos de onda do espectro eletromagnético vermelho e infravermelho próximo (NIR) e calcular a relação entre esses comprimentos de onda, um índice sensível à atividade fotossinteticamente ativa à vegetação é produzido (ROUSE et al., 1974; TUCKER, 1979). A clorofila de plantas verdes saudáveis absorve mais luz no comprimento de onda vermelho e devido à estrutura da célula vegetal, características de reflexão mais altas são registradas no comprimento de onda NIR (NOURI et al., 2017).

O NDVI é a razão da diferença entre a banda do infravermelho próximo (NIR) e a banda vermelha (RED), e a soma dessas duas bandas (ROUSE et al. 1973):

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

O algoritmo NDVI tira vantagem do fato de que a vegetação verde reflete menos luz visível e mais NIR, enquanto a vegetação esparsa ou menos verde reflete uma porção maior do visível e menos de NIR. NDVI combina essas características de refletância em uma proporção de modo que o intervalo dos valores obtidos está entre -1 e +1, conforme observado na Tabela 1. Presume-se que, apenas os valores positivos correspondam a zonas com vegetação e quanto maior o índice, maior o teor de clorofila das plantas (NOURI et al., 2017).

Tabela 1. Valores de NDVI para diferentes tipos de coberturas (DALEZIOS, 2002).

Tipo de cobertura	NDVI (escala de -1 a 1)
Vegetação densa	0.500 <= NDVI < =1
Vegetação mediana	0.140 <= NDVI < 0.500
Vegetação escassa	0.090 <= NDVI < 0.140
Solo nu	0.025 <= NDVI < 0.090
Nuvens	0.002 <= NDVI < 0.025
Gelo e neve	-0.046 <= NDVI < 0.002
Água	-1 <= NDVI < -0.046

No contexto florestal, o NDVI, além de ser utilizado para distinguir e classificar florestas primárias e secundárias em diferentes estados de regeneração, devido à sua

relação direta com a biomassa (PONZONI; SHIMABUKURO, 2009), também tem sido relacionado aos aspectos sanitários das plantas (Figura 6), sendo possível observar a evolução de patógenos em plantas, através de imagens hiperespectrais e rotinas subsequentes de análise de dados, permitindo a realização de uma detecção precoce, identificação e quantificação de diferentes doenças em diversas culturas (MAHLEIN et al., 2017).




Figura 6. Valores de NDVI associados aos aspectos sanitários das plantas. (Fonte: EOS, 2019).

Além das diversas áreas de aplicação já mencionadas, o NDVI é reconhecido como uma excelente ferramenta para verificação de áreas degradadas (BAI et al., 2008). Aplicações recentes desse índice também envolveram questões socioeconômicas (SUTTON et al., 2016; VU et al., 2014) e análises de tendências de degradação e regeneração (BARRIO et al., 2016; ECKERT et al., 2015).

Apesar de sua ampla aplicabilidade, vários estudos indicam que os resultados da análise NDVI são difíceis de serem interpretados, já que os valores do NDVI não distinguem sinais de degradação/conservação de impactos de processos naturais adversos/benéficos (RIVA et al., 2017). Além disso, os padrões NDVI podem mudar em função do clima (tendências de precipitação a longo prazo) e sazonalidade (dentro do ano hidrológico), substrato geológico e fatores geomórficos (inclinação e aspecto do terreno) (SHI-BO, XIN-SHI, 2013).

O uso do NDVI para identificar seringais infestados por *M. exigua* tem sido objeto de vários estudos recentes (DUARTE et al., 2019; LEMES et al., 2020; PEZZONI FILHO et al., 2018).

Duarte et al. (2019), recomendaram o uso do NDVI para a determinação de locais de amostragem de solo e raízes de seringueira para a averiguação da presença de *M. exigua*. Além disso, relacionando os dados de precipitação e temperatura, estabeleceram o melhor período para amostragens e confirmação da infecção radicular por *M. exigua*, enquanto que, neste caso, os meses com melhor correlação para infestação do solo foram de dezembro a fevereiro.

Já Lemes et al. (2020), constataram que a relação entre as densidades dos nematoides e os índices espectrais da vegetação é melhor expressa por correlações, paramétricas ou não, do que por equações polinomiais. Estes mesmos autores verificaram que usando índices espectrais de vegetação, preferencialmente o NDVI, pode-se distinguir um seringal não infestado de um infestado por *M. exigua*.

Utilizando uma abordagem aprimorada de sensoriamento remoto com base nos dados combinados do solo e índices NDVI em um intervalo de tempo, Valle Júnior et al. (2019), propuseram metodologia em que é definido um limite inferior e superior de valores de NDVI dos pixels ($NDVI_{pixel}$) em uma abordagem que utiliza a coincidência de acurácia em várias imagens dentro de um intervalo de tempo para validação do mapeamento das características de interesse. Esta metodologia ao ser aplicada para a averiguação de áreas com pastagens degradadas, apresentou um nível de acurácia de 84,1%.

Geralmente, o uso apenas de valores espectrais ou recursos de vetor de mudança espectral em dois perfis de tempo independentes é insuficiente para atender às necessidades de detecção precisa de variações (HU; DONG; BATUNACUN, 2018) e o GEE traz esta possibilidade, permitindo a verificação, não só de alterações, mas também de coincidências existentes ao longo do tempo (VALLE JÚNIOR, 2019).

2.4 Sentinel-2

O sensoriamento remoto (SR) tem sido utilizado como um método indispensável para aquisição de dados para monitoramento de áreas agrícolas (DEFOURNY et al., 2019). Têm surgido diversos avanços nas tecnologias de SR desde o surgimento da agricultura de precisão (MULLA, 2013). Estes avanços atraíram muitos pesquisadores

para estudar o uso de técnicas com satélites de SR para monitoramento em diversos aspectos na agricultura (BELDA et al., 2020; d'ANDRIMONT et al., 2020; GAO et al., 2020; LUO et al., 2020; CORTEZ et al., 2020; JUNG; KIM, 2020; NZIMANDE et al., 2020).

Um dos satélites que tem destaque no uso do SR em áreas agrícolas é o Sentinel-2 (S2), que é uma missão gerida pela Agência Espacial Europeia (ESA) e que fornece dados com uma combinação altamente eficaz de resoluções espaço e tempo (ESCOLÀ et al., 2017). Como resultado, S2 foi rotulado como uma melhoria sem precedentes no setor óptico de SR para a realização do monitoramento de safras em grandes áreas agrícolas em nível de campo, quase em tempo real (DEFOURNY et al., 2019). Portanto, S2 tem sido a base para uma vasta quantidade de aplicações agrônômicas (ESCOLÀ et al., 2017; NASRALLAH et al., 2019; STENDARDI et al., 2019; BELDA et al., 2020; d'ANDRIMONT et al., 2020).

S2 carrega o Multi Spectral Instrument (MSI) (DRUSCH et al., 2012). Sentinel-2A foi lançado em 23 de junho de 2015 e Sentinel-2B foi lançado em 7 de março de 2017 em órbitas circulares de 786 km com inclinação de $98,62^\circ$ e tempos de cruzamento equatorial de 10h30 e com atraso de fase de 180° (ESA, 2015). Os dados são adquiridos com um campo de visão de $20,6^\circ$ fornecendo uma faixa de aproximadamente 290 km, e o ciclo de repetição equatorial de cada sensor Sentinel-2 é de 10 dias e cinco dias quando combinados.

Segundo Gascon et al. (2017), S2 MSI é um gerador de imagens “push-broom” baseado em filtro. Ele realiza medições em 13 bandas espectrais espalhadas pelos domínios Visível e Infravermelho Próximo (VNIR) e Infravermelho de Ondas Curtas (SWIR) com resoluções espaciais que variam de 10 a 60 m (Figura 7). Esses canais espectrais incluem:

- 4 bandas com resolução espacial de 10 m: azul (490 nm), verde (560 nm), vermelho (665 nm) e infravermelho próximo (842 nm).
- 6 bandas com resolução espacial de 20 m: 4 bandas estreitas usadas principalmente para caracterização da vegetação na borda vermelha (705 nm, 740 nm, 783 nm e 865 nm) e 2 bandas SWIR mais largas (1610 nm e 2190 nm) para aplicações como detecção de neve / gelo / nuvem ou avaliação do estresse de umidade da vegetação.

- 3 bandas com resolução espacial de 60 m para aplicações como triagem de nuvens e correções atmosféricas (443 nm para aerossóis, 945 nm para vapor d'água e 1.375 nm para detecção de cirrus).

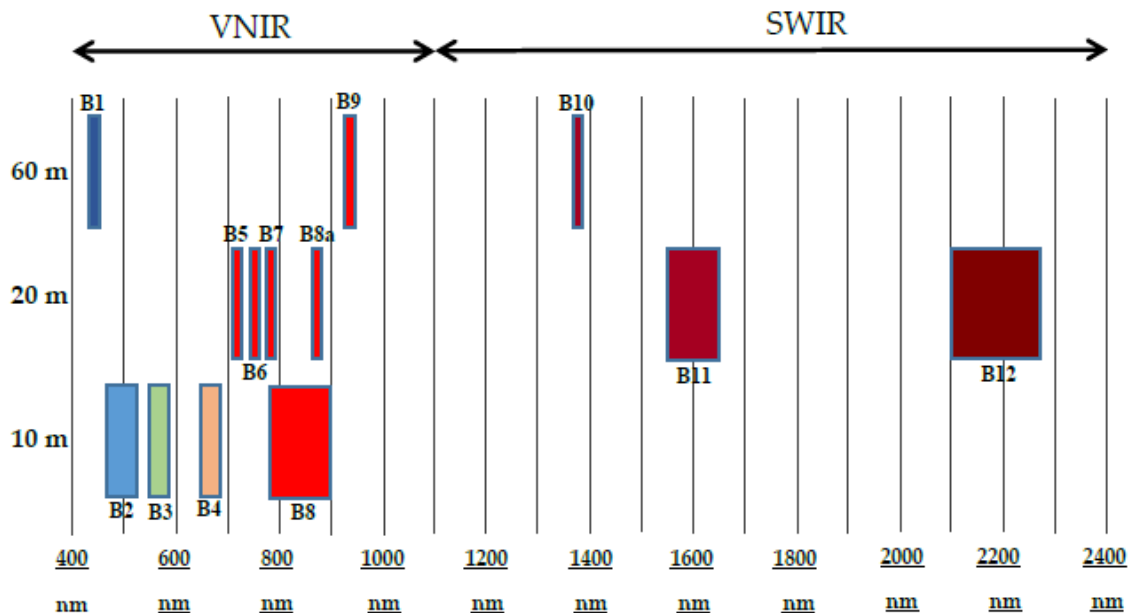


Figura 7. Bandas espectrais registradas pelos sensores MSI a bordo dos satélites Sentinel-2. (Fonte: GASCON et al., 2017).

Em função das múltiplas possibilidades que o S2 proporciona, diversas pesquisas relacionadas a florestas plantadas e seu comportamento tem utilizado suas imagens como ferramenta de processamento (JIA et al., 2019; NOMURA; MITCHARD, 2018; POORTINGA et al., 2019). Recentemente, utilizando o S2, pesquisadores conseguiram identificar seringais em expansão com base nas características decíduas da cultura (XIAO et al., 2020).

2.5 Google Earth Engine

O Google Earth Engine (GEE) é uma plataforma de computação em nuvem projetada para armazenar e processar grandes conjuntos de dados (em escala de petabyte) para análises e tomadas de decisão nos mais variados campos de pesquisa (MUTANGA; KUMAR, 2019).

Um dos grandes entraves que a área de SR tem é a necessidade de equipamentos computacionais robustos para processar os diversos dados obtidos pelos satélites. O

GEE tem os recursos que possibilitam o processamento em nuvem, sem que o usuário tenha a necessidade de ter um computador potente, de forma automática em uma plataforma computacional rápida e eficaz, mesmo trabalhando com processamento de arquivos muito grandes (GORELICK et al., 2017; HIRD et al., 2017).

O GEE fornece várias funções para realizar operações espectrais e espaciais em uma única imagem ou em um lote de imagens, variando de operações matemáticas simples a avançados algoritmos utilizados para o processamento de imagens (AMANI et al., 2020).

Observando a área de trabalho (Figura 8), janela inicial do GEE, destaca-se o editor de código que é designado para processar os dados e desenvolver aplicações usando uma linguagem de programação JavaScript (AMANI et al., 2020). A linguagem JavaScript é uma das linguagens de programação mais utilizadas, sendo utilizada para desenvolver diversos aplicativos e sistemas (ABDALLAH; AL RIFAEI, 2017).

GEE combina petabytes de conjuntos de dados SR ao longo de quatro décadas e produz um vídeo global, com zoom e sem nuvens no espaço e no tempo em sua plataforma EE Time-lapse (GORELICK et al., 2017). A plataforma Timelapse é um exemplo do grande poder computacional da plataforma GEE (AMANI et al., 2020).

Desde a disponibilização do GEE, diversas aplicações agrícolas que incluem estimativa de produção de safra, mapeamento de áreas de cultivo, vulnerabilidade de pragas e doenças, entre outras, foram estudadas usando a computação em nuvem do GEE como plataforma de pesquisa (MUTANGA; KUMAR, 2019).

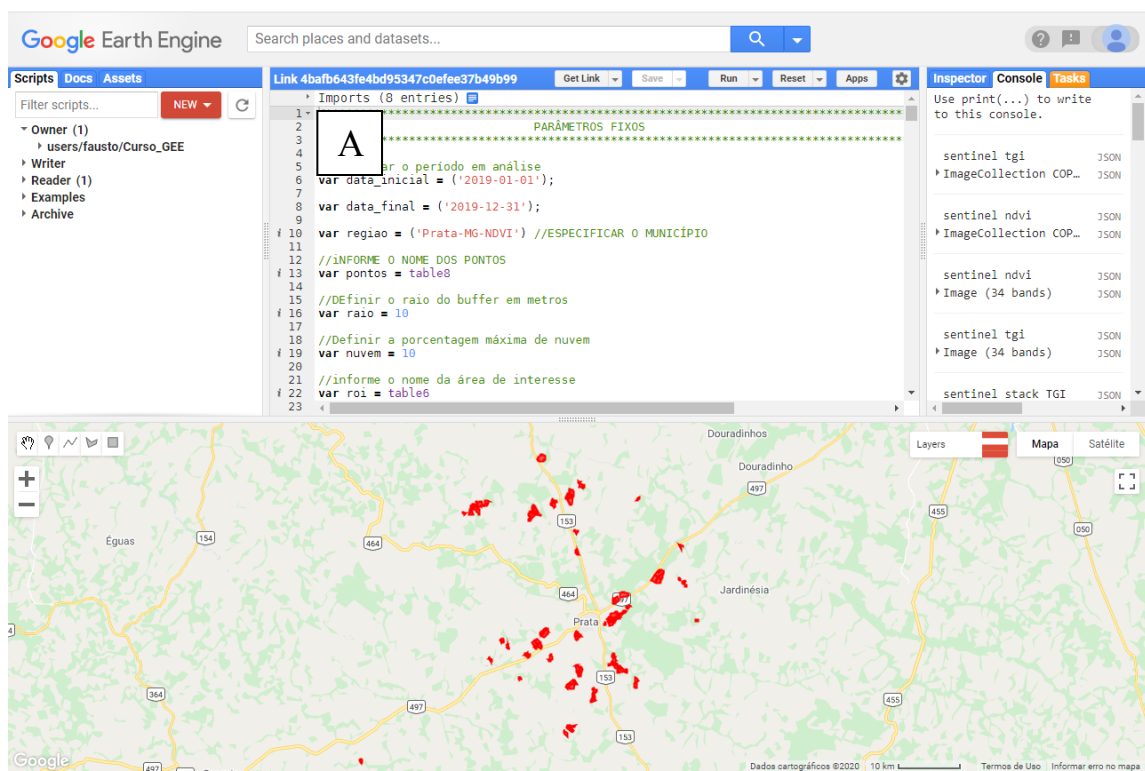


Figura 8. Área de trabalho do Google Earth Engine. A. Editor de código em linguagem de programação JavaScript.

3 MATERIAL E MÉTODOS

3.1 Área de estudo

O município de Prata, localizado no estado de Minas Gerais, foi escolhido como objeto de estudo devido ao grande avanço da heveicultura no município na última década, localizado na região do Triângulo Mineiro, Minas Gerais, nas coordenadas geográficas 19° 17' 56" Sul e 48° 54' 51" Oeste, com altitudes que variam de 497 a 865 metros (Figura 9). É válido destacar que esta região tem altitudes compatíveis com o cultivo de seringueira, já que este não é recomendado para áreas com altitudes acima de 1000 metros, devido às baixas temperaturas no período noturno (ORTOLANI et al., 1982).

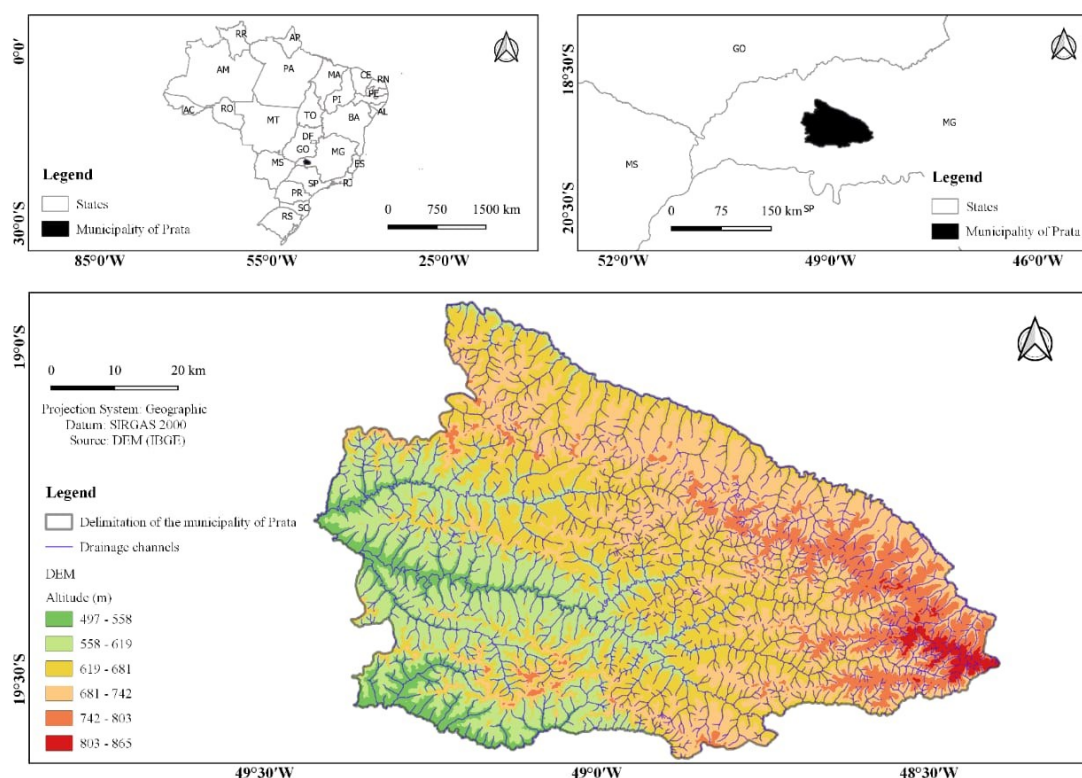


Figura 9. Mapa de localização e altitude da área de estudo.

De modo geral, o clima da região é classificado como Aw, com verões chuvosos de novembro a abril e invernos secos de junho a agosto (ALVARES et al., 2013). Os dados de precipitação, temperatura, altitude e classificação climática de Köppen Geiger, foram obtidos do arquivo suplementar de Alvares et al. (2013) e foram utilizados para estimar a umidade do solo, deficiente e excedente (balanço hídrico), resultando no comportamento estimado anual da precipitação, evapotranspiração potencial e

evapotranspiração real (Figura 10).




Figura 10. Precipitação, evapotranspiração potencial (ETP) e evapotranspiração real (ETR) para o município de Prata (Adaptado de ALVARES et al., 2013).

As condições climáticas que indicam a aptidão para o plantio de seringueira são: temperatura média anual maior que 18°C, temperatura média do mês mais frio entre 15 e 20°C e a deficiência hídrica anual menor do que 300 mm (Figura 11) (ORTOLANI et al., 1982). Tais condições coincidem com a área de estudo, o que confirma que a área de estudo é apta ao cultivo de seringueira.




Figura 11. Reposição, deficiência, excedente e retirada hídrica para o município de Prata, MG (Adaptado de ALVARES et al., 2013).

Quanto à geologia, ocorrem na área do município de Prata as unidades da Bacia do Paraná, pertencentes ao Grupo São Bento, formação Serra Geral, e ao Grupo Bauru, formações Uberaba, Marília e Vale do Rio do Peixe (Figura 12).




Figura 12. Mapa geológico do município de Prata, MG.

Além das diferentes formações geológicas, a área do município de Prata, também possui diferentes tipos de uso e ocupação do solo. Como é possível observar na Figura 13, a área urbana ocupa uma fração mínima (587 ha) da área territorial total do município (484.754,40 ha) (IBGE, 2012). A maior parte da área rural do município de Prata é ocupada por pastagens (287.509,00 ha), seguida de uma quantidade significativa de áreas de uso agrícola (56.344,00), também há frações da área ocupadas por florestas nativas (115.692,00) e florestas plantadas (24.709,00), sendo que nessa última fração, estão localizados os seringais objeto do presente estudo.

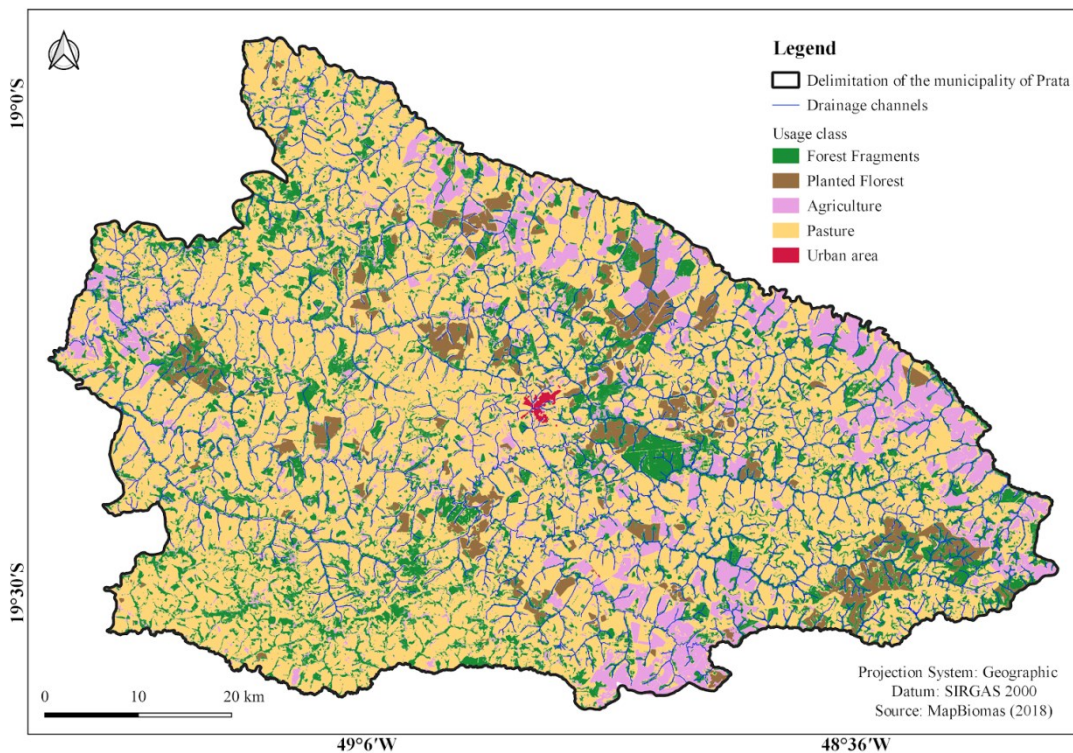


Figura 13. Mapa de uso e ocupação do solo do município de Prata, MG.

3.2 Fluxo de trabalho

O fluxo de trabalho técnico usado para mapear o índice de incidência de *Meloidogyne* sp. nos seringais do município de Prata está retratado na Figura 14.

O primeiro passo compreende um campo de pesquisa para identificar fisionomias dos seringais presentes na área de estudo. Para maior precisão, as áreas foram delimitadas manualmente através do software QGIS, onde, por meio da visualização de imagens de satélite, foi possível distinguir as áreas de seringueiras dos demais povoamentos florestais através da análise visual do formato da copa, coloração e a uniformidade da distribuição nas áreas de plantio. Foram consideradas as áreas em que o seringal apresentava o dossel totalmente fechado, os seringais tidos como novos, em que o dossel ainda encontrava-se aberto, foram descartados.

Assim que os seringais eram identificados era gerado um polígono da área com o uso do software QGIS para criação de máscara com a área de cada propriedade. Cada área encontrada foi delimitada e criado um arquivo *shape file*, totalizando 135 arquivos, para que posteriormente fosse possível sua utilização no processamento das próximas

etapas. Ao final de todo o processo de delimitação dos seringais, foi contabilizada uma área total de 2.733,06 ha.

Posteriormente, foi necessário determinar pontos de treinamento para que fossem obtidos os valores de NDVI que seriam utilizados como indicador da presença de nematoides de galha ($NDVI_{\text{nematoide}}$). Desta forma, foram coletadas 43 amostras georreferenciadas de solo e raízes em 2 seringais com histórico de incidência de nematoides de galha para a confirmação da contaminação. Confirmada a presença de *Meloidogyne* sp. em todas as amostras foi possível prosseguir com a metodologia proposta.

Com as áreas de seringueiras já delimitadas e os pontos de treinamentos já aferidos, todas as imagens do satélite SENTINEL-2 da área de estudo, disponíveis durante o ano de 2019, foram submetidas ao NDVI com intuito de verificar o comportamento do $NDVI_{\text{nematoide}}$. Com uso das imagens disponíveis pelo satélite no ano (33 imagens), já excetuando automaticamente, pelo filtro do GEE, as imagens contaminadas com ruído ou 10% de nuvens, foi possível realizar a estatística zonal e verificar o comportamento dos $NDVI_{\text{nematoide}}$ com os demais pixels, considerados pixels de áreas não contaminadas, $NDVI_{\text{livre}}$, imagem por imagem, determinando o período em que realmente existe diferença significativa entre os pixels de interesse.

Neste momento foi importante observar o comportamento de todos os valores NDVI e verificar alguma discrepância pontual no comportamento dos valores. Por se tratar de uma área muito extensa, mesmo com o filtro de 10% de nuvens, existe a possibilidade de alguns polígonos apresentarem contaminação por nuvem. Assim, foi necessário verificar cada um dos polígonos em 3 datas que apresentavam comportamento anormal, onde em todas as 3 foi verificado a presença de nuvens em algumas áreas de seringueira. Por isso, foi necessário a exclusão das imagens destas 3 datas, a fim de eliminar o erro dos valores de NDVI proveniente da interceptação de nuvens sobre as áreas de interesse.

Determinado o período do ano em que as imagens apresentam diferença significativa entre $NDVI_{\text{nematoide}}$ e $NDVI_{\text{livre}}$, realizou-se o processo de classificação binária utilizando apenas as imagens deste período. No processo de classificação binária, todos os $NDVI_{\text{nematoide}}$ serão reclassificados como 1 e os $NDVI_{\text{livre}}$ como 0. Por fim, todas as imagens da série temporal utilizadas nesta última etapa foram empilhadas e somadas para que se considerasse a localização de todos $NDVI_{\text{nematoide}}$ para geração de um único mapa.

Para validação do mapa foi necessário que uma nova amostragem de verdade de campo fosse realizada, agora com intuito de validação do mapa criado. Trinta e duas amostras foram coletadas ao acaso, em áreas consideradas contaminadas e não contaminadas, e realizou-se a análise nematológica. A constatação de que os resultados obtidos com as amostras de verdade de campo coincidem com os indicados pelo mapa fazem a validação do mesmo.

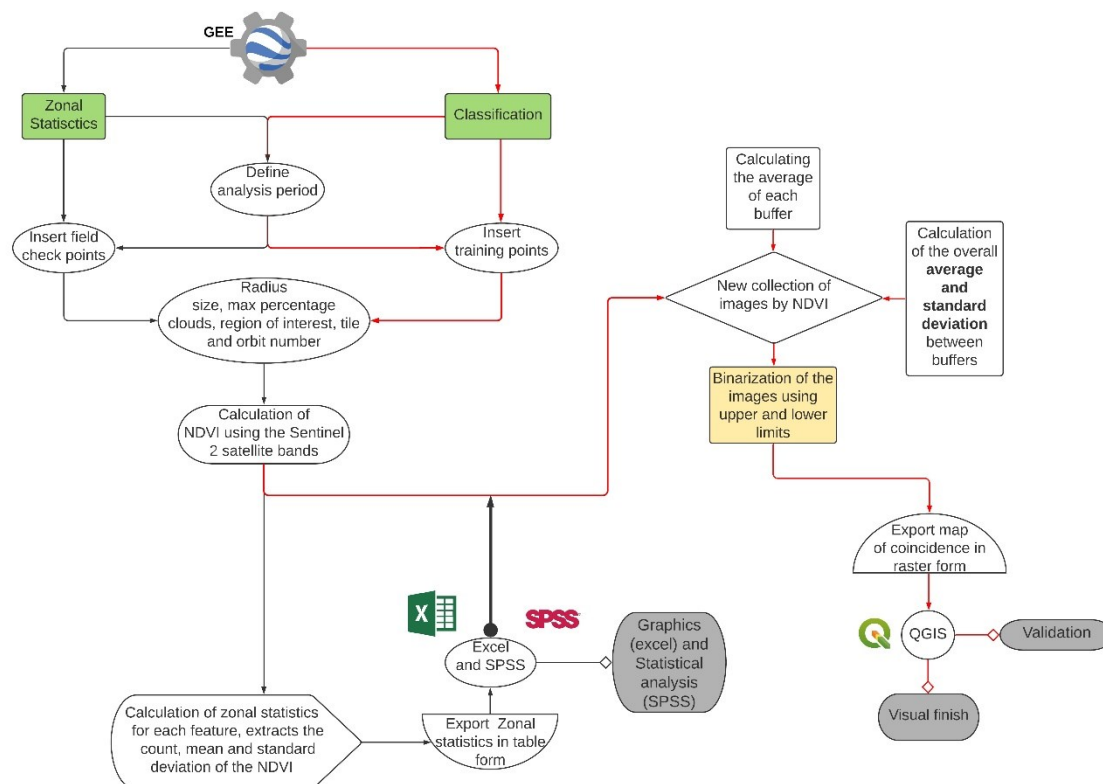


Figura 14. Fluxograma referente ao fluxo de entradas e saídas dos scripts “Zonal Statistics” e “Classification”.

3.3 Conjuntos de dados e software

O QGIS é um sistema de informação geográfica livre e de código aberto que permite criar, editar, visualizar e analisar informação geoespacial em diversas plataformas. Para a viabilização desta pesquisa, este software foi utilizado para a criação dos arquivos com a delimitação dos seringais do município de Prata. Posteriormente, também foi utilizado para a geração e acabamento dos mapas finais.

A plataforma GEE foi utilizada para aquisição das imagens do Sentinel-2 e para a criação do script com automação de boa parte das ações atribuídas na metodologia de processamento de imagens proposta neste estudo.

Os dados das análises quali-quantitativas nematológicas georreferenciadas, incluídas a estatística zonal dos dados espectrais (NDVI) foram tabulados no Excel, com gráficos elaborados no mesmo programa. Já as análises estatísticas foram executadas no IBM SPSS Statistics versão 20.

3.4 Caracterização dos locais da verdade para treinamento

O georreferenciamento e caracterização dos locais de verdade terrestre tiveram como objetivo estabelecer pontos amostrais que foram utilizados para a determinação do $NDVI_{nematóide}$.

Para isso, foi necessário a identificação de áreas com o histórico da presença de nematóides de galha na seringueira. Então, conforme proposto, foram identificados 2 seringais onde se procedeu a coleta de amostras de 0,5 kg de solo e 0,1 kg de raízes a uma profundidade de 0 a 0,3 m, sendo que cada ponto amostrado foi georreferenciado (Figura 15).



Figura 15. Pontos georreferenciados das amostras de solo e raiz para caracterização da verdade terrestre de treinamento. (Fonte: GOOGLE EARTH, 2019).

3.5 Determinação do valor médio e desvio padrão

A estatística zonal é baseada nos valores médios e desvio padrão dos valores de

NDVI dos pixels de interesse. Para que estas informações sejam obtidas, são estabelecidos os valores de “buffer” a serem adotados em cada ponto de treinamento, ou seja, é determinado um raio a partir de cada ponto georreferenciado que estabelecerá a média dos valores de pixel aos quais o “buffer” se sobrepõe.

Na metodologia proposta foi adotado um buffer de raio de 10 m. Esta medida adotada se deve ao fato de que as imagens disponibilizadas pelo S2 apresentam resolução que corresponde a imagens com pixels de 10 m. Desta forma, o “buffer” pode representar o valor médio de 4, 6, 7, 8 ou 9 pixels aos quais está sobreposto (Figura 16).




Figura 16. Exemplicação da obtenção de valores médios de pixels (10 m x 10 m) obtidos por delimitação em buffer com raio de 10 m. **A.** Área sem buffer; **B.** Buffer sobrepondo 4 pixels; **C.** Buffer sobrepondo 6 pixels; **D.** Buffer sobrepondo 7 pixels; **E.** Buffer sobrepondo 8 pixels; **F.** Buffer sobrepondo 9 pixels.

Em função da quantidade de pixels aos quais o “buffer” se sobrepõe e os valores correspondentes a cada pixel é determinado uma média do valor de NDVI ($NDVI_{buffer}$) e o desvio padrão dentro de cada “buffer”.

Estas informações são utilizadas para estabelecer o padrão de comportamento dos valores de NDVI dos pontos identificados com contaminação por nematoides de

galha e viabilizar a análise estatística para averiguação se realmente existe diferença significativa entre os valores de NDVI das áreas contaminadas e das áreas não contaminadas e permitir a determinação temporal para ajuste do modelo.

3.6 Classificação das imagens por NDVI aprimorado

A metodologia proposta para classificação das imagens toma como base os valores de NDVI resultantes da estatística zonal (VALLE JÚNIOR, 2019). Assim, partindo dos valores médios e do desvio padrão, propõem-se as seguintes equações para determinação do limite inferior e superior dos valores de pixel que serão classificados como indicadores da possível contaminação de seringueiras por nematoides de galha:

$$\textit{Limite inferior} = NDVI_{buffer} - \text{desvio padrão}$$

$$\textit{Limite superior} = NDVI_{buffer} + \text{desvio padrão}$$

Definidos os limites, parte-se para a etapa de binarização em que todos os pixels correspondentes ao intervalo definido dentro dos limites superiores e inferiores são reclassificados como sendo 1 e os demais pixels, com valores superiores ao limite superior ou inferiores ao limite inferior, são reclassificados como 0.

Este processo é realizado com toda série temporal de imagens. Contudo, foi utilizada a resposta obtida com a estatística zonal referente ao período adequado para distinção das áreas contaminadas por meio do NDVI. Por isso, o empilhamento das imagens se procedeu apenas com as imagens em que foi constatada diferença significativa entre os pixels contaminados e não contaminados dentro do período com índices pluviométricos e temperaturas satisfatórios para a seringueira.

Diferente do proposto por Valle Júnior (2019), não foi estabelecido um valor mínimo de coincidências para classificação da característica de interesse. Isso porque foram utilizados parâmetros estatísticos para a verificação da significância expressa pelas diferentes áreas de interesse, imagem por imagem.

Os valores dos pixels também não se somaram, mesmo quando sobrepostos na compilação das imagens das diferentes datas, foi atribuído o valor 1 para os pixels com indícios de contaminação e zero para os livres de contaminação. Desta forma o mapa

final apresenta toda informação já analisada e verificada em cada imagem (Figura 17).

JANEIRO						FEVEREIRO						MARÇO				
0	0	0	0	0		0	0	0	0	0		1	0	0	0	0
0	0	1	1	0		0	0	1	1	1		0	0	1	1	0
0	1	0	0	1	+	0	0	0	0	0	+	0	1	0	0	1
0	0	0	0	1		0	0	0	0	1		0	0	0	0	1
1	1	1	0	0		1	1	0	0	0		1	0	0	0	0
COINCIDÊNCIAS																
1																
0																
0																
0																
1																

Figura 17. Exemplo do empilhamento de imagens binárias de diferentes datas para a geração de um único mapa, também binário.

3.7 Caracterização dos locais da verdade para validação

A partir do mapa de coincidências produzido, foram definidos trinta e dois pontos com as coordenadas georreferenciadas, sorteados ao acaso nas áreas consideradas contaminadas e nas não contaminadas, para a coleta de amostras de solo e raiz no intuito de se realizar a análise nematológica como parâmetro da verdade terrestre (Figura 18). É por meio desta etapa que o mapa é validado e, em função do número de acertos e erros, é calculada a acurácia do mapa.

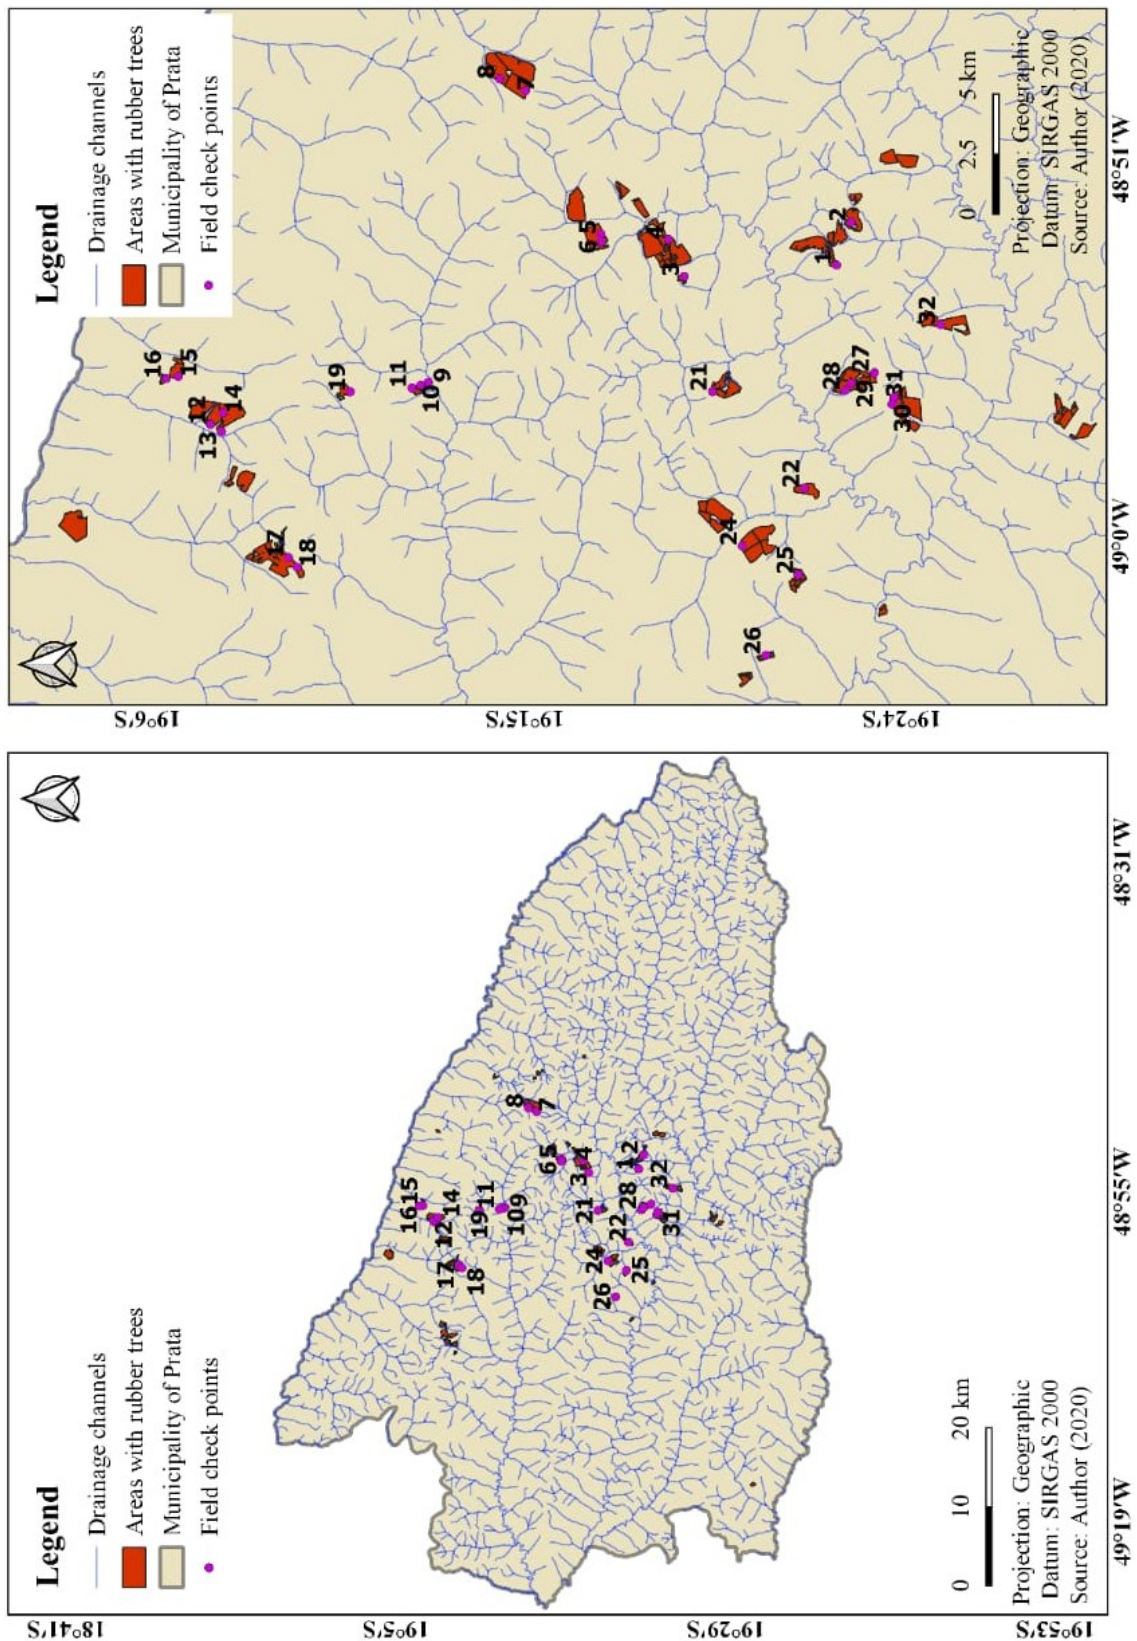


Figura 18. Distribuição dos 32 pontos para coleta de amostras de solo e raiz como parâmetros para a verdade terrestre.

Com as coordenadas de cada ponto de verdade terrestre, utilizando um receptor

de GPS de navegação modelo Garmim GPSMAP® 78, foi possível localizar todos os pontos de interesse. Contudo, nem sempre as coordenadas levavam aos locais mais apropriados para a coleta das amostras, que seria mais próximo às linhas de plantio onde era possível observar a presença de sistema radicular secundário em abundância. Devido à necessidade de ajuste do local para a coleta das amostras, o ponto de cada amostra coletada foi novamente georreferenciado e, posteriormente atualizado na validação do mapa.

Diferentes fisionomias foram observadas e alguns registros fotográficos foram feitos para que fosse possível contrastar os resultados das análises com o diagnóstico visual constatado *in loco* (Figura 19).




Figura 19. Fisionomias dos seringais de Prata, MG: **A.** Seringal não contaminado; **B.** Seringal contaminado; **C.** Seringal contaminado com seringueiras subdesenvolvidas; **D.** Seringal contaminado com seringueiras mortas.

As amostragens foram realizadas no período de 13 a 17 de julho de 2020. Em

cada amostra georreferenciada foram coletados aproximadamente 0,5 kg de solo e 0,1 kg de raízes a uma profundidade de 0 a 30 cm no solo (Figura 20). As análises foram realizadas pelo laboratório de análises nematológicas LabZap, em Uberaba, MG. A metodologia para os procedimentos das análises de solo e raízes seguiram a metodologia proposta por Bonetti e Ferraz (1981) e Jenkins (1964) respectivamente.




Figura 20. Exemplo de ponto para coleta das amostras da verdade terrestre: **A.** Limpeza do local para amostragem; **B.** Retirada de amostra de solo e raiz.

3.8 Acurácia e concordância da classificação

Qualquer proposta de metodologia de classificação de mapas e imagens de satélite é concluída com a verificação da precisão que o modelo obteve. Para isso, a forma mais simples e comum é a verificação da porcentagem classificada corretamente em relação às amostras coletadas para a verdade de validação. Esta verificação é conhecida como acurácia. Geralmente é derivada da classificação correta das características de interesse pela amostragem dos dados de classificação e é demonstrada pela matriz de confusão e o coeficiente de Kappa (CONGALTON, 1991).

A matriz de confusão é uma matriz quadrada de números estabelecidos em linhas e colunas, representando o número de unidades de amostragem atribuídas a uma determinada categoria onde são listados os valores preditos como verdadeiros ou falsos e, posteriormente, validados como realmente sendo verdadeiros ou falsos. Estas

denominações são usualmente descritas como verdadeiro positivo (VP), verdadeiro negativo (VN), falso positivo (FP) e falso negativo (FN). Tal modelo permite verificar a precisão e sensibilidade da metodologia proposta (CONGALTON; GREEN, 1999).

O coeficiente de concordância de Kappa permite correlacionar o valor do coeficiente com a Tabela de interpretação de Kappa (ANEXO 1) em que quanto mais próximo de 1 for o valor, maior é o indicativo de que existe uma concordância entre o real e o predito, e quanto mais próximo de zero, maior é o indicativo de que a concordância é puramente aleatória (LANDIS; KOCH, 1977).

3.9 Script para automação da metodologia

O uso da plataforma Google Earth Engine possibilitou otimizar o fluxo de trabalho (Figura 14). Inicialmente foi elaborado um script “Zonal Statistics” (Apêndice 1) para a obtenção de série temporal dos índices de vegetação de cada ponto de checagem, e exportado em formato de planilha para realizar análise estatística em softwares apropriados.

Outro script “Classification” (Apêndice 2) foi desenvolvido e possibilitou classificar áreas de seringueira quanto ao indício da presença de nematoides de galha, através do conceito de classificação supervisionada proposto por Valle Júnior (2019), nesse caso é necessário saber locais com presença confirmada de nematoides e com isso é feita a extrapolação. Ao fim é exportado um mapa em formato GeoTIFF.

4 RESULTADOS

4.1 Análise nematológica

Ao término da extração dos nematoides nas amostras de solo e raiz, os resultados das 32 amostras foram expressos em porções de 150 cm³ solo, para as amostras de solo, e grama de raiz, para amostras de raiz (Apêndice 3). Constatou-se a presença de nematoides em todas as amostras, destacando-se a presença do nematoide *Pratylenchus* sp., presente em todas as amostras com populações consideravelmente elevadas, seguido por *Aphelenchoides* sp., o qual não foi observado em apenas 2 das 32 amostras analisadas. Já *Meloidogyne* sp., esteve presente em 18 amostras. Conforme previsto no planejamento do estudo, existem áreas isentas de sua presença, o que permitiu a verificação de sua distribuição nos seringais do município. Além dos nematoides anteriormente citados, também foi constatada a presença de *Criconemella* sp. em 18 amostras, *Rotylenchus* sp. em 2 amostras, *Aphelenchus* sp. em 2 amostras, e *Helicotylenchus* sp. em 1 amostra.

Os gêneros de nematoides presentes em cada amostra podem ser observados na Tabela 2.

Tabela 2. Presença de diferentes gêneros de nematoides em amostras de solo e raiz coletadas no município de Prata, MG, no mês de julho de 2020.

Identificação da amostra	Nematoides	Identificação da amostra	Nematoides
1	M, P, Aes, Aus	17	M, P, Aes, C
2	M, P, Aes	18	M, P, Aes, C
3	M, P, Aes, C	19	P, Aes, Aus
4	P, Aes	20	P, Aes
5	M, P, Aes, C	21	P, Aes
6	M, P, H	22	M, P, C, R
7	M, P, Aes	23	P, Aes, C
8	P, Aes	24	M, P, Aes, C
9	P, Aes, R	25	P, Aes, C
10	P, Aes	26	M, P, Aes, C
11	P, Aes	27	M, P, Aes, C
12	P, Aes, C	28	M, P, Aes, C
13	M, P, Aes	29	P, Aes, C
14	M, P, Aes, C	30	P, Aes, C
15	M, P, Aes	31	M, P, Aes, C
16	P, Aes, C	32	M, P, Aes, C

*P= *Pratylenchus* sp, M= *Meloidogyne* sp, R= *Rotylenchulus* sp, Aes= *Aphelenchoides* sp, C=*Criconemella* sp, R= *Rotylenchus* sp, Aus= *Aphelenchus* sp, H= *Helicotylenchus* sp.

Ao se observar a distribuição populacional dos nematoides fitopatogênicos de maior representação nas amostras, *Aphelenchoides* sp., *Pratylenchus* sp. e *Meloidogyne* sp. (Figura 21) é possível notar grande diferença nas densidades populacionais. A maior população encontrada no somatório dos resultados obtidos das amostras de solo e raiz foi de *Pratylenchus* sp. nas amostras 23, com 1.372 nematoides, e na 24, com 1.552 nematoides, correspondentes a uma única propriedade rural, enquanto que o menor número foi obtido nas amostras 1 e 6, com 12 indivíduos cada. As duas maiores populações de *Meloidogyne* sp. foram de 196, na amostra 18, e de 192, na amostra 24, esta última sendo a mesma amostra em que se constatou a maior população de *Pratylenchus* sp. Por fim, o nematoide *Aphelenchoides* sp. apresentou população bem discreta com a maior população sendo verificada na amostra 9, com 32 nematoides.




Figura 21. Nematoides encontrados em amostras de solo (150 cm^{-3} solo) e raiz (g^{-1} raiz), provenientes de seringais no município de Prata, MG, coletados em julho de 2020.

Ao se analisar separadamente o número de nematoides por tipo de amostra, solo ou raiz, percebe-se a tendência de prevalência de alguns gêneros em um dos tipos de amostra (Figura 21).

As amostras de raiz possibilitam observar com mais clareza os nematoides que efetivamente têm a seringueira como hospedeira. Apenas a população de *Pratylenchus sp.* quantificados nas amostras de raiz representaram 84,26%, seguido pela população de *Meloidogyne sp.* que representou 13,41% e *Aphelenchoides sp.* com apenas 2,13%. Além destes nematoides mencionados, também foram identificados *Helicotylenchus sp.* e *Criconemella sp.*, representando apenas 0,13% e 0,07% da população de nematoides

contabilizados nas amostras de raiz.

Já nas amostras de solo, a proporção das populações identificadas apresentou comportamento bem diferente do observado nas amostras de raiz, onde *Pratylenchus* sp. correspondeu a 33,19% das amostras, *Meloidogyne* sp. a 23,19%, *Criconemella* sp. a 21,43%, *Aphelenchoides* sp. a 19,34%, *Aphelenchus* sp. e *Rotylenchus* sp., que só foram detectados nas amostras de solo, 1,98% e 0,88% respectivamente, *Helicotylenchus* sp. não foi encontrado no solo.

Ao se retratar a proporção dos nematoides considerados danosos à cultura da seringueira, *Meloidogyne* sp. e *Pratylenchus* sp., percebe-se que suas populações estão concentradas no sistema radicular da planta, enquanto que os demais nematoides apresentam maior proporção no solo (Figura 22).

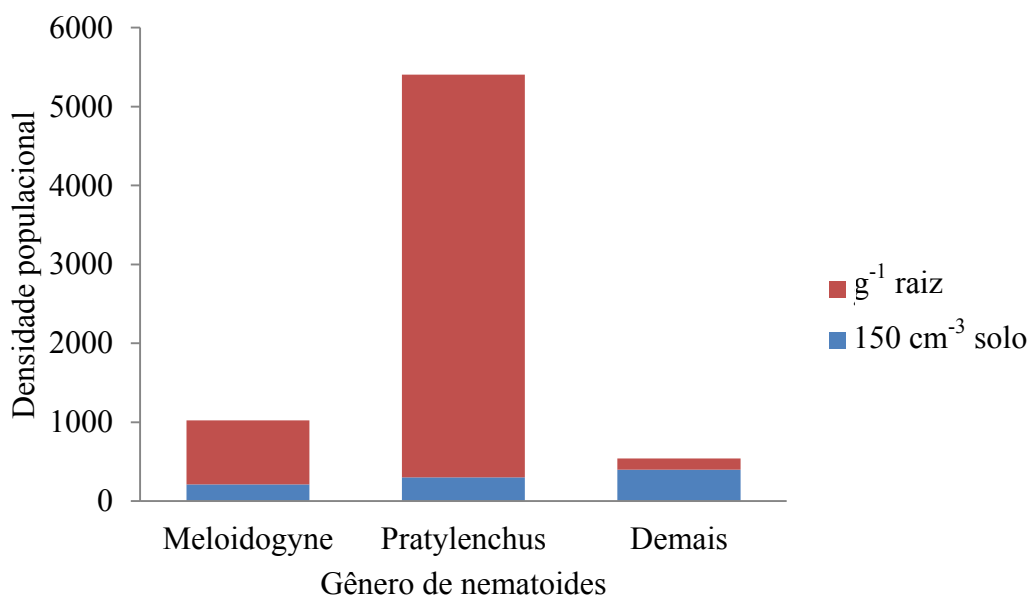


Figura 22. Nematoides encontrados em amostras de solo e raiz, provenientes de seringais no município de Prata, MG, coletados em julho de 2020.

A expressiva população de *Pratylenchus* sp. encontrada no sistema radicular pode ser explicada por se tratar de um patógeno polífago, com ampla gama de hospedeiros e ser migrador, enquanto que *Meloidogyne* sp. é sedentário e, se se confirmar como *M. exigua*, ter um único hospedeiro – a própria seringueira.

Utilizando o modelo generalizado com distribuição Poisson, foi possível comparar a distribuição da probabilidade resposta, ou seja, a distribuição populacional de *Meloidogyne* sp. e *Pratylenchus* sp. (Tabela 3).

TABELA 3. Análise de deviance da distribuição populacional de *Meloidogyne* sp. e *Pratylenchus* sp.

		Df	Deviance Resid.	Df	Resid. Dev	Pr(>Chi)
Solo	NULL			63	913.15	
	Nematoides	1	16.228	62	896.92	5.616e-05 ***
Raiz	NULL			63	16577	
	Nematoides	1	3465.8	62	13111	< 2.2e-16 ***
Total	NULL			63	16534	
	Nematoides	1	3274.8	62	13259	< 2.2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Percebe-se que a diferença entre as populações é considerada muito significativa. É possível relacionar tal diferença a dois fatores, sendo o primeiro ao histórico das áreas que, em sua maioria, tiveram pastagens como cultura antecessora aos seringais, justificando a presença de *Pratylenchus* sp. em todas as amostras.

Já a densidade populacional muito maior do que a encontrada para *Meloidogyne* sp. se deve ao período de amostragem. A densidade populacional de *Meloidogyne* sp. torna-se baixa no período do inverno devido à seringueira apresentar comportamento caducifólio. Contudo, nematoides migradores, como *Pratylenchus* sp acabam apresentando estabilidade populacional.

As médias populacionais apresentaram grande discrepância e ao se comparar as médias populacionais totais e das raízes de *Meloidogyne* sp. e *Pratylenchus* sp. (Tabela 4), esta diferença fica bem evidente.

TABELA 4. Comparação de médias entre as populações de *Meloidogyne* sp. e *Pratylenchus* sp.

	Nematoide	Rate	SE	LI	LS	
Solo	<i>Meloidogyne</i> sp.	6.59	0.454	5.58	7.61	a
	<i>Pratylenchus</i> sp.	9.44	0.543	8.22	10.65	b
Raiz	<i>Meloidogyne</i> sp.	25.4	0.89	23.4	27.4	a
	<i>Pratylenchus</i> sp.	159.4	2.23	154.4	164.4	b
Total	<i>Meloidogyne</i> sp.	32	1,0	29,7	34,2	a
	<i>Pratylenchus</i> sp.	169	2,3	163,7	174,0	b

IC de SIDAK: Solo $((9.44-6.59)/6.59)*100 = 43.25\%$; Raiz $((159.4-25.4)/25.4)*100 = 527.56\%$; Total $((169-32)/32)*100 = 428.13\%$.

Independentemente da amostra, solo, raiz, solo+raiz, a população de *Pratylenchus* sp. foi significativamente superior à de *Meloidogyne* sp. Ao se considerar todas as 32 amostras, a população total de *Pratylenchus* sp., com média 169 nematoides $(150 \text{ cm}^{-3} \text{ solo} + \text{g}^{-1} \text{ raiz})$, é 428,13% superior à população de *Meloidogyne* sp., que

apresentou uma média de 32 nematoides (150 cm^{-3} solo + g^{-1} raiz). Todavia, ao se discriminar apenas as amostras em que foram encontrados os respectivos nematoides, a média de *Meloidogyne* sp. sobe para 56,83 nematoides.

A população encontrada no sistema radicular foi a que apresentou maior diferença, com a população de *Pratylenchus* sp. 527,56% maior em comparação ao *Meloidogyne* sp. Todavia, apesar de significativa diferença, a população destes nematoides no solo apresentou médias mais próximas, 6,59 *Meloidogyne* sp. e 9,44 *Pratylenchus* sp. por 150 cm^3 solo.

4.2 Determinação temporal para ajuste do modelo

A fim de estabelecer o período ideal de aquisição e verificação do NDVI para geração do mapa temático com a resposta binária (área infestada ou não infestada) foi realizado o cálculo da estatística zonal, que retorna o número de pixels, média e desvio padrão dentro de cada buffer. Neste momento foram utilizadas as informações em relação às amostras da verdade de validação.

Na estatística inferencial, o primeiro teste efetuado é o de normalidade, sendo aplicado o teste de normalidade de Kolmogorov-Smirnov. Neste, analisando a distribuição por data e classificação (infestado ou não com nematoides), ficou evidente que, na maioria das vezes, a distribuição dos dados não segue distribuição normal.

Para melhor interpretação e observação visual, foi possível elaborar um gráfico que representou de forma clara a média do NDVI das áreas saudáveis, visualmente maiores que as contaminadas, exceto de julho a setembro de 2019 (Figura 23).




Figura 23. Perfil do NDVI médio de seringais contaminados e não contaminadas por *Meloidogyne* sp. no município de Prata, MG.

Objetivando analisar estatisticamente esta proposição, realizou-se teste não paramétrico de amostras independentes, U de Mann-Whitney (Tabela 5). Desta forma, foi possível verificar que entre 07/07/2019 e 21/08/2019, não houve diferença estatística entre seringais infestados e não infestados, assim como nas datas 15/09/2019, 20/09/2019 e 30/09/2019.

É evidente que os valores de NDVI no período em que os seringais perdem suas folhas deveriam ser iguais em ambas as situações avaliadas. Contudo, apesar da retomada de diferença significativa, já na imagem de 26/08/2019, as imagens passam a não se diferir novamente de 15 a 20 de setembro, provavelmente devido à típica inconstância das chuvas ocorridas neste período. De qualquer forma, existe retomada da diferença em outubro, mês em que se tem o início dos períodos mais chuvosos na região. Provavelmente, o início do período de altos índices pluviométricos acentuariam novamente padrões semelhantes de diferenças significativas observados no início do ano.

TABELA 5. Teste de U de Mann-Whitney para os valores médios de NDVI de áreas contaminadas e não contaminadas por *Meloidogyne* sp.

Valor médios de NDVI			
Data (Sentinel-2)	Áreas contaminadas	Áreas não contaminadas	valor p
08/01/2019	0.848	0.909	.001
13/01/2019	0.857	0.899	.000
23/01/2019	0.852	0.897	.001
28/01/2019	0.844	0.902	.000
09/03/2019	0.849	0.882	.004
29/03/2019	0.814	0.870	.000
03/04/2019	0.809	0.855	.000
28/04/2019	0.793	0.853	.002
08/05/2019	0.798	0.857	.001
18/05/2019	0.745	0.804	.007
28/05/2019	0.776	0.824	.001
02/06/2019	0.776	0.823	.003
07/06/2019	0.756	0.812	.001
12/06/2019	0.736	0.780	.005
17/06/2019	0.694	0.763	.001
22/06/2019	0.613	0.693	.002
07/07/2019	0.371	0.410	.051
12/07/2019	0.322	0.348	.069
27/07/2019	0.423	0.422	.933
11/08/2019	0.813	0.781	.611
16/08/2019	0.835	0.813	.582
21/08/2019	0.843	0.836	.099
26/08/2019	0.815	0.834	.020
31/08/2019	0.817	0.831	.018
05/09/2019	0.822	0.851	.008
10/09/2019	0.825	0.846	.028
15/09/2019	0.829	0.857	.051
20/09/2019	0.615	0.638	.075
30/09/2019	0.828	0.845	.069
05/10/2019	0.816	0.841	.014
15/10/2019	0.817	0.841	.020

Valores p destacados apresentam diferença significativa entre os índices NDVI de áreas contaminadas e não contaminadas.

4.3 Mapa da infestação de nematoides das galhas

Trabalhando com os resultados obtidos pelo teste de Mann-Whitney, com a diferença significativa entre os valores da estatística zonal, foi possível estabelecer o período do ano em que os valores de NDVI, apresentando indícios de infestação pelo

nematoide de galha, tornam-se distintos dos observados nas áreas sem contaminação. Esta resposta possibilitou a seleção das imagens que realmente expressam, por meio da reflectância espectral, sintomas referentes à incidência do nematoide de galhas.

Assim, gerou-se o NDVI apenas das 18 imagens obtidas no período de 08 de janeiro a 16 de junho e dos dias 05 e 15 de outubro. Posteriormente, as imagens geradas foram reclassificadas impondo-se um padrão binário (infestado ou não infestado), estabelecendo como contaminados por nematoides das galhas os pixels que apresentavam os valores de NDVI dentro dos limites superiores e inferiores, determinados conforme metodologia mencionada anteriormente.

Com as 18 imagens reclassificadas de forma binária, realizou-se o empilhamento das mesmas para que o somatório de todas as informações obtidas na data de cada imagem pudessem ser unificadas para a geração de um único mapa temático indicando as áreas com suspeita de contaminação por nematoides de galha.

Com isso, foram gerados 135 mapas indicando as áreas com a suspeita de infestação por nematoide de galha. Os mapas abrangendo as áreas onde foram coletadas as amostras para a verdade de campo foram compilados em um único mosaico de imagens (Figura 24) onde foram indicados os pontos em que foram realizadas as coletas das amostras de verdade de campo.

Desta forma, foram contabilizados 1.983,44 hectares diagnosticados com a suspeita de infestação por nematoides de galha, correspondendo a 72,57% dos 2.733,06 hectares de seringais em idade de fechamento de dossel, independentemente se estavam em produção ou não.

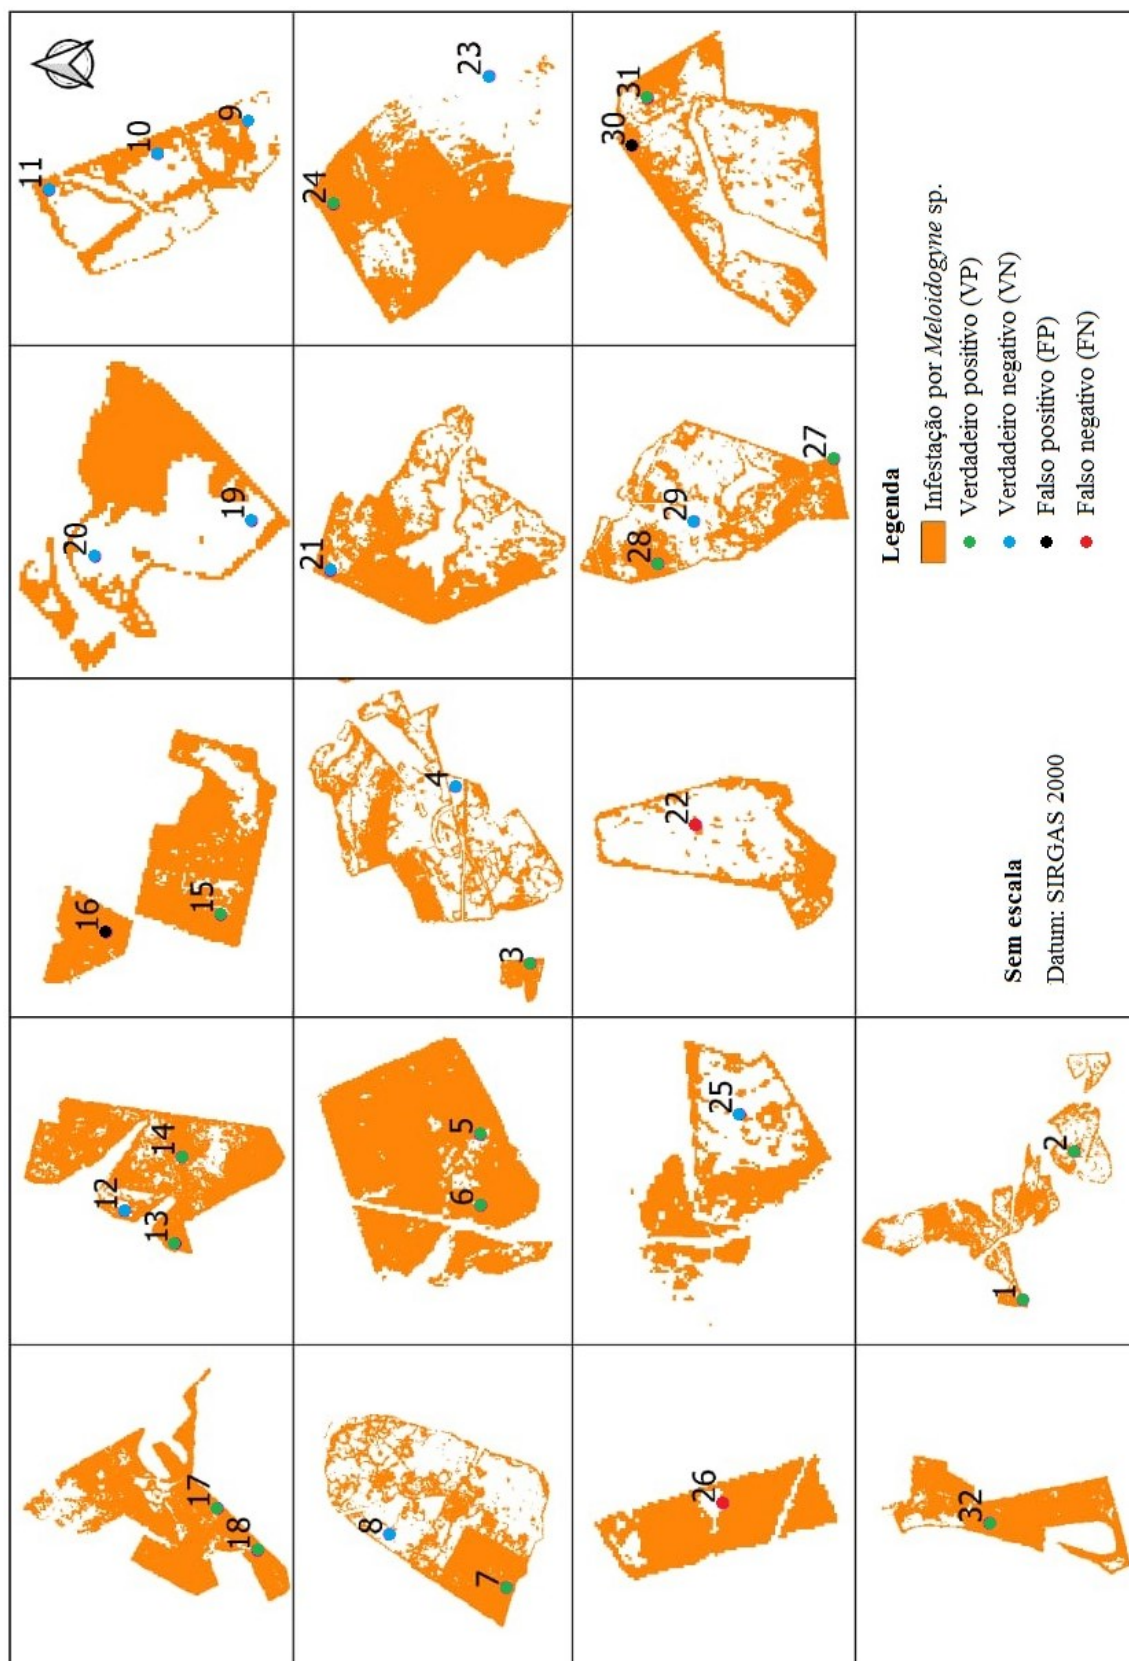


Figura 24. Mapa temático com classificação binária discriminando áreas com índice de infestação por nematoides de galha.

4.4 Acurácia da classificação

Para se determinar a acurácia obtida pela metodologia proposta, levou-se em consideração os resultados obtidos pelas análises nematológicas e a coincidência do que foi observado no mapa classificado com a metodologia proposta. Estas informações permitem que seja constatado o fitonematoide que realmente teve influência nos valores espectrais observados nesta pesquisa.

Assim foi proposta a construção da matriz de confusão (Tabela 6) com os valores referentes ao número de amostras de verdade de validação correspondentes à verdade positiva (VP), verdade negativa (VN), falso positivo (FP) e falso negativo (FN).

Em relação ao *Meloidogyne* sp., dos 32 dois pontos de verdade de validação, 12 foram considerados VN e outros 16 VP, totalizando 28 pontos amostrados que corresponderam ao que foi classificado no mapa. Esta proporção de acertos validou a classificação do mapa com 87,5 % de acurácia, além do índice Kappa de 0,75. O fato de terem sido observados 2 amostras para cada caracterização falsa, FP e FN, resultou em valores iguais de sensibilidade e precisão, 88,89%. Sendo que, para o objetivo em que a metodologia de classificação foi utilizada, o FN tem maior importância devido aos problemas que ele pode proporcionar em áreas com este tipo de diagnóstico.

É interessante verificar que os nematoides *Pratylenchus* sp. e *Aphelenchoides* sp. apresentaram alta precisão, 100% e 94,44% respectivamente. Contudo, esta precisão reflete a grande disseminação destes nematoides nas áreas de seringueira e, ao contrastarmos este valor com os demais valores obtidos na Matriz de confusão, chega-se ao índice Kappa de apenas 0,11.

Tabela 6. Matriz de confusão construída com as informações obtidas no mapa classificado e as informações da verdade de validação.

Fitonematoides	Verdade de campo	Classificado		Total	*Ac (%)	*Se (%)	*Pr (%)	*K
		-	+					
<i>Meloydogyne</i> sp.	-	12 (VN)	2 (FP)	14	87,50	88,89	88,89	0,75
	+	2 (FN)	16 (VP)	18				
	Total	14	18	32				
<i>Pratylenchus</i> sp.	-	0 (VN)	0 (FP)	0	56,25	56,25	100	0,11
	+	14 (FN)	18 (VP)	32				
	Total	14	18	32				
<i>Aphelenchoides</i> sp.	-	1 (VN)	1 (FP)	2	56,25	56,67	94,44	0,11
	+	13 (FN)	17 (VP)	30				
	Total	14	18	32				
<i>Criconemella</i> sp.	-	8 (VN)	6 (FP)	14	62,50	66,67	66,67	0,24
	+	6 (FN)	12 (VP)	18				
	Total	14	18	32				
<i>Rotylenchus</i> sp.	-	12 (VN)	18 (FP)	30	37,50	0	0	-
	+	2 (FN)	0 (VP)	2				
	Total	14	18	32				
<i>Aphelenchus</i> sp.	-	13 (VN)	17 (FP)	30	43,75	50	5,56	-
	+	1 (FN)	1 (VP)	2				
	Total	14	18	32				
<i>Helicotylenchus</i>	-	14 (VN)	17 (FP)	31	46,88	100	5,56	-
	+	0 (FN)	1 (VP)	1				
	Total	14	18	32				

*Ac – Acurácia; Se – Sensibilidade; Pr – Precisão; K – Índice Kappa de concordância

5 DISCUSSÃO

5.1 Distribuição de nematoides

Todas as áreas de seringueira avaliadas tem em comum o histórico de pastagens como cultura anterior à implantação dos seringais, sendo que diversos estudos já apontaram a frequente associação de *Pratylenchus* sp. com gramíneas, leguminosas forrageiras e, inclusive, diversas plantas infestantes (SHARMA et al., 2001; STANTON et al., 1989). Assim, ao ser introduzida em áreas com a presença de *Pratylenchus* sp. a seringueira se torna mais um hospedeiro, permitindo que a população deste nematoide se mantenha no local. Em seringais saudáveis, com o fechamento das copas das árvores, há uma redução de plantas infestantes e a população de *Pratylenchus* spp. diminui. Também é possível que, no período de senescência da seringueira, haja um aumento de plantas infestantes, favorecendo o aumento transiente da população deste patógeno.

No período da avaliação, julho, a população de *Pratylenchus* sp. foi maior que as demais populações encontradas nos seringais. Bernardes et al. (2015), já haviam relatado a infecção de porta-enxertos de seringueira por *P. brachyurus*, mostrando-se patogênico para os clones GT1 e RRIM600, nos quais diminuiu significativamente o crescimento do diâmetro do caule. Paes-Takahashi et al. (2015), verificaram tal patogenicidade em 8 clones diferentes, sendo eles PB235, PB217, RRIM501, PR255, IAN873, e TJ1, além de GT1 e RRIM600, considerando os clones avaliados como sendo suscetíveis a *M. exigua* e *P. brachyurus*.

Apesar da constatação de susceptibilidade das mudas de seringueiras ao *P. brachyurus*, a reprodução deste nematoide e os danos causados em mudas de seringueira tem se mostrado bem menores quando comparados a *M. exigua* (PAES-TAKAHASHI et al., 2015). Desta forma, a explicação para a constatação de grandes populações e a ampla distribuição de *Pratylenchus* sp. nos seringais de Prata se dá devido à pré-existência do patógeno nas áreas, anteriormente formadas por pastagens, o fato de que a seringueira é suscetível ao mesmo e, mesmo no período em que os seringais entram em senescência, seu hábito migrador e ampla gama de plantas hospedeiras permite a manutenção de uma alta densidade populacional.

Por outro lado, a espécie de *Meloidogyne* encontrada nos seringais tem apresentado comportamento seletivo, sendo considerado patógeno exclusivo de seringueiras. Além disso, a constatação de que este nematoide não é encontrado em

todas as propriedades do município, tendo sua população concentrada em algumas, indica que é provável que este nematoide tenha sido introduzido por meio de mudas contaminadas, sendo esta uma das principais formas de disseminação deste patógeno pelos seringais no Brasil (PAES-TAKAHASHI, 2015).

Os valores populacionais discrepantes entre *Meloidogyne* sp. e *Pratylenchus* sp. constatados nas amostras de raiz se devem a alguns fatores já observados em outros estudos. Souza et al. (2019), acompanharam a variação populacional de *M. exigua* do mês de novembro de 2016 a abril de 2017, em seringal implantado no Triângulo Mineiro, e observaram uma queda significativa no decorrer destes meses, com a última amostragem de abril apresentando menos da metade da população verificada em novembro. Já a dinâmica populacional observada por Carvalho et al. (2019), sugeriu relação da diminuição de *M. exigua* em seringueiras com a diminuição da precipitação, umidade do solo e também a senescência da seringueira ocorrida geralmente no mês de julho.

Na estação de inverno, nas regiões onde a seringueira foi inserida, o desenvolvimento das raízes mais finas, responsáveis por grande parte da absorção de águas e nutrientes, é praticamente interrompido. Além disso, morrem algumas das raízes finas que haviam sido colonizadas por *Meloidogyne* sp., liberando a massa de ovos, já eclodida em decorrência das chuvas esparsas, comuns nos meses de maio, diminuindo drasticamente a população de *Meloidogyne* sp. (CARVALHO et al., 2019).

5.2 Série temporal para análise

A verificação do padrão NDVI das áreas infestadas e não infestadas durante o ano evidenciou o comportamento caducifólio dos seringais, permitindo observar uma queda abrupta do NDVI entre julho e agosto, independente da infestação por estes fitopatógenos, período este coincidente aos 2 meses iniciais do inverno do Hemisfério Sul, ocorrendo retomada dos valores do NDVI após este período. Desta forma, compreendendo que o NDVI é resultante da biomassa da área da copa fotossinteticamente ativa, alguns fatores edafoclimáticos alteram bruscamente o dossel, ou seja, ocorre desfolhamento (queda de folhas senescentes) e reenfolhamento natural (brotação e desenvolvimento de folhas) após o período de hibernação.

Analisando os dados da série histórica para composição do Balanço Hídrico

Climático e compreendendo que há equilíbrio dinâmico da área evapotranspirante das folhas com a disponibilidade hídrica no solo, oriunda das precipitações, é possível observar que a redução da chuva e conseqüentemente água disponível no solo, tem influência no padrão de decréscimo dos valores NDVI ao longo do início do ano, porém o aumento do NDVI ao patamar anterior ocorre antes do reinício das chuvas, desta forma, existem outros fatores influenciadores do comportamento do reenfolhamento dos seringais, como a temperatura, que também apresenta boa relação com o comportamento dos seringais, conseqüentemente influenciando nos valores do NDVI.

Como há sinais de que a sazonalidade da área foliar e NDVI da seringueira são determinados pela temperatura e precipitação, compreendendo que a espécie é de origem equatorial, com pouca amplitude térmica, oscilando de 26 a 30 °C, a hipótese é que a senescência das folhas ocorrida no inverno demore a reestabelecer o comportamento sintomático discriminado por meio das análises de NDVI, tanto pelas questões fisiológicas quanto pela retomada de crescimento populacional de *Meloidogyne* sp.

A partir do mês de julho após a queda das folhas dos seringais, os padrões de NDVI deixam de apresentar diferença estatística (Tabela 5). Além disso, em função dos altos índices pluviométricos a partir de novembro, a utilização de imagens de satélite fica prejudicada com a contaminação pela presença de nuvens e sombras das nuvens. Por outro lado, os dados mostram que o intervalo de dados coletados do mês de julho ao mês de setembro não possibilitaram a diferenciação entre as áreas contaminadas e não contaminadas.

Chen e Cao (2015) sugerem que uma combinação de características hidráulicas, características de troca gasosa e as condições hídricas durante a estação seca podem desencadear uma mudança nos hábitos foliares de *H. brasiliensis* em áreas introduzidas. Condição que causa grande estresse, levando-as a uma complexa retranslocação de N, P e K por toda a planta durante a renovação foliar, reestabelecendo de forma lenta seus padrões normais após o início das chuvas e aumento da temperatura (LI et al., 2016).

Da mesma maneira como foi levado em consideração o comportamento caducifólio nos seringais de Prata, neste caso, com intuito de aprimorar a resposta do NDVI obtido na série temporal do período, diversas pesquisas utilizando NDVI tem se atentado para o comportamento caducifólio em diferentes espécies florestais, verificando seu comportamento fenológico para diversas finalidades (TESTA et al.,

2018; DEKA et al., 2019; KOWALSKI et al., 2020; RECANATESI et al., 2020; SINHA et al., 2020).

Desta forma, é possível afirmar que foi fundamental a verificação do comportamento da série temporal de NDVI como parâmetro para determinação da escolha das imagens para aprimorar a aplicação da metodologia de classificação proposta por Valle et al. (2019), no presente estudo, utilizada na verificação de incidência de *Meloidogyne* sp. em seringais.

5.3 Diagnóstico de *Meloidogyne* sp. com NDVI aprimorado

O uso do NDVI como ferramenta para diagnosticar a presença e severidade de infecções causadas por nematoides tem sido estudado em diversas culturas, inclusive na seringueira (MARTINS et al., 2017; DUARTE et al., 2019; BALABEL et al., 2020; GROOVER; LAWRENCE, 2020; LEMES et al., 2020; VIERA-TORRES et al., 2020)

Em estudo recente, Lemes et al. (2020), já apresentavam resultados demonstrando que o sensoriamento remoto seria capaz de diferenciar um seringal não infestado de um infestado pelo nematoide de galha *M. exigua*, em especial por meio do uso do índice NDVI.

A grande vantagem da metodologia proposta foi a possibilidade de diagnosticar diversas propriedades distribuídas em um extenso território. Além disso, o aprimoramento do NDVI, ao se utilizar uma seleção de imagens da série temporal baseado na observação da significância da diferença dos valores médios do NDVI ao longo do ano, possibilitou um refinamento do resultado final. Normalmente, as pesquisas realizadas no mesmo intuito proposto no presente estudo, além de não apresentarem uma abordagem de série temporal também desconsideram as oscilações de NDVI decorrentes principalmente do clima e da fisiologia da planta.

Alguns trabalhos têm negligenciado a importância de se fazer uma análise criteriosa da série temporal das imagens pesquisadas. No caso do café, cultura em que se tem observado diversas publicações acerca do uso do sensoriamento remoto para o diagnóstico de nematoides (MARTINS et al., 2017; CORTEZ et al., 2020; ABREU JÚNIOR et al., 2020; LE, 2020; SILVA et al., 2021), mesmo sabendo que o índice de área foliar apresenta alta variabilidade espacial e temporal, influenciando na relação entre as variáveis biofísicas (JARAMILLO-GIRALDO et al., 2019), tais circunstâncias são desconsideradas.

Em estudo realizado por Martins et al. (2017), utilizando uma classificação multispectral para avaliar a intensidade de nematoides em uma propriedade de café, os aspectos temporais em sua pesquisa foram considerados irrelevantes, alegando-se que, por ser uma cultura perene, o cafeeiro não sofreria alterações biofísicas no intervalo de uma mesma safra. Assim, mesmo com o uso de imagens de um satélite com excelente resolução, RapidEye, e avaliando uma pequena área, estes autores alcançaram uma acurácia geral de apenas 78% e coeficiente Kappa de 0,71.

Da mesma forma, Silva et al. (2021), desconsideraram o uso de série temporal ao analisar imagens multiespectrais de satélite com o objetivo de detectar pragas e doenças em cafezais e utilizaram a imagem de uma única data. Contudo, os próprios autores enfatizaram que o uso de imagens de diferentes estados fenológicos possibilitaria melhor caracterização do comportamento espectral da cultura.

Outra forma que tem sido muito utilizada para obtenção de imagens para o processamento, detecção e monitoramento de nematoides em plantas é a captura de imagens por meio de veículos aéreos não tripulados (VANT) (QIN et al., 2016; MAGNUSSON et al., 2017; TZOVARAS et al., 2019; NIU et al., 2020; WU et al., 2020). Todavia, este tipo de avaliação demanda bastante trabalho, já que é necessário que o equipamento sobrevoe toda a área a ser avaliada e, em casos da obtenção de séries temporais, se torna ainda mais onerosa (TZOVARAS et al., 2019; WU et al., 2020).

Em estudo mais recente, Abreu Júnior et al. (2020) utilizaram os mesmos princípios apresentados nesta pesquisa para verificação de acurácia do modelo, alcançando 80% de acurácia e um índice Kappa de 0,75, ao trabalharem com VANT para verificação de nematoides em cafezal pelo método de máxima verossimilhança. Tal metodologia acaba se limitando a propriedades rurais específicas, diferente da metodologia proposta que tem o intuito de fazer uma verificação global em diversas áreas dentro de um município.

A verificação de extensas áreas e o constante monitoramento, essencial para órgãos de fiscalização, demanda ferramentas que possam dar respostas eficientes e rápidas. Outro fator importante do modelo proposto é que, além de ser barato, permite automação de grande parte das operações.

A atual metodologia proposta apresentou resultados satisfatórios quanto à validação dos dados. Os valores de acurácia, 87,5%, sensibilidade e precisão, 88,9%, alcançaram índices que indicam que a metodologia é aplicável de forma satisfatória (VALLE JÚNIOR, 2019).

Além disso, outro fator a se destacar é a baixa representatividade de amostras FN, apenas 2. É importante ressaltar que amostras FN são as menos desejadas neste tipo de abordagem de diagnóstico, pois podem incorrer na não verificação ou na falta de tomadas de decisões sobre áreas infestadas por *Meloidogyne* sp. mas que foram classificadas como não apresentando indícios de infestação. Por outro lado, as amostras FP, ao indicarem o local para coleta das amostras nematológicas e não apresentarem contaminação, não implicam em grandes prejuízos. De qualquer forma, ambas as situações foram pouco representativas nos resultados.

O resultado da análise do coeficiente de concordância de Kappa com valor de 0,75 indica que a interpretação das informações do mapa gerado apresentam fortes indícios de serem verdadeiras (LANDIS; KOCH, 1977).

5.4 Gestão dos resultados

Os nematoides de galha são considerados os nematoides parasitas de plantas mais destrutivos, abrangendo mais de 4.000 plantas hospedeiras consideradas suscetíveis (DECRAEMER et al., 2013; JONES et al., 2013). Diversas formas de controle químico, cultural e biológico tem apresentado eficiência em diversas culturas (RAMAMOORTHY, 2001; OLIVEIRA et al., 2017; OLIVEIRA et al., 2019; EL-BATAL et al., 2019; INT, 2019). Contudo, o uso de cultivares resistentes é considerado ideal para o controle de nematoides (WILCKEN et al., 2005; OLIVEIRA et al., 2015).

Diante de áreas com infestação de nematoides, como as encontradas em Prata, é necessário que seja realizado algum tipo de manejo. Contudo, existe grande dificuldade em se controlar os fitonematoídes, devido à grande quantidade de plantas infestantes e sua variabilidade genética, o que restringe o seu controle à redução da densidade populacional (CORREIA, 2013). Infelizmente, as formas de controle conhecidas para os nematoides não tem apresentado resultados satisfatórios para a cultura da seringueira, já que, conforme destacado por Sharma e Junqueira (1996), a presença de apenas 0,001 ovos por grama de solo já é considerado danoso para a cultura, sendo a prevenção ainda a melhor opção (CARVALHO et al., 2013). A principal forma de controle de nematoides de galha é a produção e comercialização de mudas sadias, isentas do patógeno, já que a principal forma de disseminação de *M. exigua* se dá pela comercialização de mudas contaminadas (PAES-TAKAHASHI et al., 2016).

A presença de altas infestações de nematoides em seringais pode levar à queda

de até 61,98% na produção de coágulo (MACHADO, 2018). Considerando que essa diminuição na produção se desse em todas as áreas diagnosticadas pelo algoritmo como prováveis áreas de infestação por nematoides, teríamos uma redução de 44,98% na produção de coágulo do município de Prata. Por isso, as propriedades produtoras de mudas devem se basear nas boas práticas de produção de mudas, garantindo que as mudas estejam livres de *Meloidogyne* sp. e *Pratylenchus* sp. Além disso, a Coordenadoria de Defesa Agropecuária (CDA) do Estado de São Paulo, por meio da Resolução SAA – 154 de 22 de novembro de 2013, determina que as mudas de seringueira devem ser produzidas em substrato isento de solo, com materiais vegetativos de propagação cadastrados e em viveiros suspensos (SÃO PAULO, 2013). Desta forma, por meio de medidas preventivas na produção de mudas, tem se tentado minimizar a disseminação de nematoides pelos seringais.

Apesar de haver uma instrução normativa para todo país, Instrução Normativa MAPA nº 26/2018, não se menciona a necessidade de existir controle em relação à comercialização de mudas isentas de nematoides, conforme constava na Instrução Normativa MAPA nº 29/2009, que estabelecia em seu artigo 32 que as mudas deveriam estar livres de nematoides *Meloidogyne* spp. e *Pratylenchus* spp. (BRASIL, 2009; BRASIL 2018). Contudo, no estado de São Paulo ainda se mantém a resolução mais restritiva, que preconiza as boas práticas de produção de mudas. Mesmo assim, ainda falta conscientização dos produtores e fiscalização nas diversas regiões em que ocorre o cultivo de seringueira. Diversos estados brasileiros, como Minas Gerais, onde está situado o município do estudo, não apresentam legislação específica para boas práticas de produção de mudas de seringueira.

Neste contexto, a ferramenta apresentada pode ser utilizada para que uma abordagem seja direcionada às áreas identificadas com suspeitas de contaminação pelo patógeno, possibilitando tal constatação sem a necessidade de deslocamentos, coleta de materiais e análises, que até então não teriam um critério técnico para definição dos pontos amostrais. Outras iniciativas, como o esclarecimento dos heveicultores sobre o patógeno e a adoção de restrições para comercialização de mudas oriundas de áreas infectadas, podem minimizar os prejuízos nas propriedades e evitar que a disseminação ocorra de forma involuntária.

6 CONCLUSÕES

A metodologia desenvolvida para verificação da presença de *Meloidogyne* sp. pode ser considerada válida por apresentar acurácia de 87,5 % e índice Kappa de 0,75. No entanto, mesmo sendo válida, é necessário salientar que a metodologia aponta áreas com indícios da presença de *Meloidogyne* sp. e, desta forma, é necessário a coleta de amostras de solo e raiz para a verificação e confirmação laboratorial.

Utilizando a plataforma de processamento geoespacial Google Earth Engine, com base na coincidência das imagens NDVI ao longo de um ano, verificou-se que a eliminação de amostras discrepantes, por “contaminação” de nuvens, e a verificação do período apropriado para a constatação de padrões NDVI adequados à determinação de diferença entre as prováveis áreas infestadas e não infestadas foi fundamental para o sucesso da metodologia. No caso da seringueira, os períodos de janeiro a junho e o mês de outubro foram os mais adequados para o diagnóstico de prováveis áreas infestadas com *Meloidogyne* sp.

Foi possível criar um padrão de script a ser utilizado na plataforma Google Earth Engine que automatiza o processo de geração dos valores de pixels para análise estatística e, posteriormente, outro script para a classificação da imagem. Contudo, não foi possível automatizar todo o processo e um único script, sendo necessário analisar os dados gerados no script “Zonal Statistics” para a determinação do melhor período da série temporal a ser utilizado na segunda etapa do processo, que seria o script de classificação propriamente dito.

Constatou-se grande disseminação de *Pratylenchus* sp. nos seringais de Prata, sendo encontrado em todas as amostras coletadas. Já *Meloidogyne* sp. foi verificado em 18 das 32 amostras, o que indica uma disseminação mais pontual do patógeno, provavelmente por meio das mudas. Também foram identificados outros 6 gêneros de nematoides, em baixas densidades populacionais e sem indícios de patogenicidade à seringueira.

A área com indícios de infestação de *Meloidogyne* sp. foi estimada em 1.983,44 hectares, correspondendo a 72,57% dos 2.733,06 hectares de seringueira identificados, dentro do município de Prata (Minas Gerais, Brasil).

É importante salientar que os resultados obtidos na presente pesquisa abrem uma porta para diversas outras possibilidades desde o aprimoramento da metodologia proposta a, até mesmo, extrapolação por meio de ajustes para outras áreas com a

presença de seringais, inclusive podendo ser adaptada para diferentes culturas.

REFERÊNCIAS

- ABAD, P.; CASTAGNONE-SERENO, P.; ROSSO, M. N.; ENGLER, J. A.; FAVERY, B. Invasion, feeding and development. In: PERRY, R. N.; MOENS, M.; STARR, J. L. (Ed). **Root-knot nematodes**. Wallingford, UK: CAB INTERNATIONAL, p. 163-181, 2009.
- ABDALLAH, M.; AL RIFAEI, M. Java Standards: A Comparative Study. **International Journal of Computer Science and Software Engineering**, v. 6, p. 146-151, 1 jun. 2017.
- ABREU JÚNIOR, C. A. M. de; VINHAL, G. P.; XAVIER, L. C. M.; MARTINS, G. D.; VIEIRA, B. S. Mapeamento de nematoides na cultura cafeeira a partir de imagens multiespectrais obtidas por aeronaves remotamente pilotadas. **Caminhos de Geografia**, v. 21, n. 76, p. 72–84–72–84, 3 ago. 2020. DOI: <https://doi.org/10.14393/RCG217651255>. Acesso em: 11 nov. 2020.
- ALI, Q.; TAWEEPRED, W.; TECHATO, K. Preparation and characterization of polymer electrolyte membrane from chloroacetate chitosan/chitosan blended with epoxidized natural rubber. **Polymer Testing**, v. 82, p. 106294, 1 fev. 2020. DOI: <https://doi.org/10.1016/j.polymertesting.2019.106294>. Acesso em: 11 nov. 2020.
- ALVARENGA, A. de P. Potencial de Minas Gerais para a produção de borracha natural. **Informe Agropecuário**, v. 28, nº 237, p. 7-11, mar./abr. 2007.
- ALVARES, C.A.; STAPE, J.L.; SENTELHAS, P.C.; GONÇALVES, J.L.M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Berlin, v. 22, n. 6, p.711-728. 2013.
- ALVES, P. V. V. **Nematoides associados à cultura da soja na região integrada de desenvolvimento do Distrito Federal e entorno-ride**. 2015. 79 f. Dissertação (Mestrado em Fitopatologia) - Universidade de Brasília, Brasília, 2015. Disponível em: https://repositorio.unb.br/bitstream/10482/19525/1/2015_PedroVictorVerlageAlves.pdf. Acesso em: 03 jan. 2020.
- AMANI, M.; GHORBANIAN, A.; AHMADI, S. A.; KAKOOEI, M.; MOGHIMI, A.; MIRMAZLOUMI, S. M.; MOGHADDAM, S. H. A.; MAHDAVI, S.; GHAHREMANLOO, M.; PARSIAN, S.; WU, Q.; BRISCO, B. Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 5326–5350, 2020. DOI: <https://doi.org/10.1109/JSTARS.2020.3021052>. Acesso em: 14 nov. 2020.
- ANON. PM 7/39 (2) *Aphelenchoides besseyi*. **EPPO Bulletin**, v. 47, n. 3, p. 384–400, dez. 2017. DOI: <https://doi.org/10.1111/epp.12432>. Acesso em: 23 jan. 2020.
- APG - ANGIOSPERM PHYLOGENY GROUP. An update of the Angiosperm Phylogeny Group classification for the orders and families of flowering plants: APG III. **Botanical journal of the Linnean Society**, 161: 105-121, 2009.

BARRIO, G. DEL; SANJUAN, M.E.; HIRCHE, A.; YASSIN, M.; RUIZ, A.; OUESSAR, M.; VALDERRAMA, J.M.; ESSIFI, B.; PUIGDEFABREGAS, J. Land degradation states and trends in the northwestern Maghreb drylands, 1998–2008. **Remote Sens.** 8, 1–25, 2016.

BAI, Z.G.; DENT, D.L.; OLSSON, L.; SCHAEPMAN, M.E. Proxy global assessment of land degradation. **Soil Use Manag.** 24 (3), 223–234. 2008.

BALABEL, N.; MAMDOUH, A. M.; YOUNES, S. N. E.-D. Efficacy of PCR-based techniques and remote sensing technology for detecting potato brown rot infection caused by *R. solanacearum*. **Egyptian Journal of Agricultural Research**, v. 98, n. 2, p. 240–269, 1 out. 2020. DOI: <https://doi.org/10.21608/ejar.2020.118061>. Acesso em: 20 nov. 2020.

BELDA, S.; PIPIA, L.; MORCILLO-PALLARÉS, P.; VERRELST, J. Optimizing Gaussian Process Regression for Image Time Series Gap-Filling and Crop Monitoring. **Agronomy**, v. 10, n. 5, p. 618, maio 2020. DOI: <https://doi.org/10.3390/agronomy10050618>. Acesso em: 21 nov. 2020.

BERNARDES, M. S.; MARTINS, A. N. Pathogenicity of *Pratylenchus brachyurus* to rubber rootstocks. **Summa Phytopathologica**, v. 41, n. 1, p. 31–34, mar. 2015. DOI: <https://doi.org/10.1590/0100-5405/1956>. Acesso em: 27 jan. 2020.

BERNARDO, E. R. A.; SANTOS, J. M.; SILVA, R. A.; CASSETARI NETO, D.; SANTOS, S. S.; DELMADI, L.; ROCHA, V. F. Levantamento de Meloidogyne exigua na cultura da seringueira em São José do Rio Claro, MT, Brasil. **Ciência Rural**, v. 33, n. 1, p. 157–159, fev. 2003. DOI: <https://doi.org/10.1590/S0103-84782003000100025>. Acesso em: 21 jan. 2020.

BERTHELOT, K.; PERUCH, F.; LECOMTE, S.; ESTEVEZ, Y. Hevea brasiliensis REF (Hev b 1) and SRPP (Hev b 3): An overview on rubber particle proteins. **Biochimie**, 2014. Disponível em: <https://agris.fao.org/agris-search/search.do?recordID=US201700120055>. Acesso em: 4 dez. 2020.

BIAN, Q. The Nature of Climate Change- equivalent Climate Change Model's Application in Decoding the Root Cause of Global Warming. **International Journal of Environment and Climate Change**, , p. 801–822, 3 dez. 2019. DOI: <https://doi.org/10.9734/ijecc/2019/v9i1230160>. Acesso em: 08 nov. 2020.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Instrução Normativa nº 29, de 05 de agosto de 2009. Aprova as normas para a produção de sementes e de mudas de seringueira (*Hevea spp.*). **Diário Oficial da República Federativa do Brasil**: seção 1, Brasília, DF, p. 5, 6 ago. 2009. Disponível em: <http://sistemasweb.agricultura.gov.br/sislegis/action/detalhaAto.do?method=consultarLegislacaoFederal>. Acesso em: 20/09/2019.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Instrução Normativa nº 26, de 04 de JUNHO de 2018. Aprova as normas de produção e comercialização de material de propagação de seringueira (*Hevea spp.*). **Diário Oficial da República Federativa do Brasil**: seção 1, Brasília, DF, p. 61, 14 jun. 2018. Disponível em:

https://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/25601942/do1-2018-06-14-instrucao-normativa-n-26-de-4-de-junho-de-2018-25601781. Acesso em: 20/09/2019.

BROWN, D.; FEENEY, M.; AHMADI, M.; LONOCE, C.; SAJARI, R.; DI COLA, A.; FRIGERIO, L. Subcellular localization and interactions among rubber particle proteins from *Hevea brasiliensis*. **Journal of Experimental Botany**, v. 68, n. 18, p. 5045–5055, 2 nov. 2017. DOI: <https://doi.org/10.1093/jxb/erx331>. Acesso em: 14 jan. 2020.

CARVALHO, C.; FERNANDES, C. D.; SANTOS, J. M.; MACEDO, M. C. M. Densidade populacional de *Pratylenchus* spp. em pastagens de *Brachiaria* spp. e sua influência na disponibilidade e na qualidade da forragem. **Revista Ceres**, v. 60, n. 1, p. 30–37, fev. 2013. DOI: <https://doi.org/10.1590/S0034-737X2013000100005>. Acesso em: 25 mar. 2019.

CARVALHO, M. F.; COELHO, L.; SANTOS, M. A. dos; COSTA, V. H. A. Dinâmica populacional de *Meloidogyne exigua* em seringal no Triângulo Mineiro. In: CONGRESSO BRASILEIRO DE HEVEICULTURA, 6. 2019, Belo Horizonte. **Anais [...]** Belo Horizonte: CBH, 2019. p. 1-3. Disponível em: http://congressodeborracha.com.br/trabalhos/14_MATHEUS_dinamica.pdf. Acesso em: 23 jan. 2020.

CASTILLO, P.; VOVLAS, N. ***Pratylenchus* (Nematoda: Pratylenchidae): Diagnosis, Biology, Pathogenicity and Management**. [S. l.]: Brill, 2007. Disponível em: <https://brill.com/view/title/13449>. Acesso em: 5 dez. 2020.

CHEN, J.-W.; CAO, K.-F. A possible link between hydraulic properties and leaf habits in *Hevea brasiliensis*. **Functional Plant Biology**, v. 42, n. 8, p. 718, 2015. DOI: <https://doi.org/10.1071/FP14294>. Acesso em: 10 jan. 2019.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35–46, 1 jul. 1991. DOI: [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B). Acesso em: 22 abr. 2019.

CONGALTON, R.; GREEN, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. 3rd Ed. 2019. DOI: <https://doi.org/10.1201/9780429052729>. Acesso em: 22 abr. 2019.

CORREIA, E. C. S. S. **Reação de cultivares de alface do grupo Americano a *Meloidogyne incognita*, *M. javanica* e *M. enterolobii***. 2013. 63 f. Dissertação (Mestrado em Proteção de Plantas) - Universidade Estadual Paulista “Júlio Mesquita Filho”, Botucatu, 2013. Disponível em: https://repositorio.unesp.br/bitstream/handle/11449/97263/correia_ecss_me_botfca.pdf?sequence=1&isAllowed=y. Acesso em: 05 out. 2019.

CORTEZ, M. L. J.; ALVES, M. C.; CARVALHO, G. R.; POZZA, E. A. Relationship between Sentinel-2 orbital data and *in situ* monitoring of coffee rust. **SN Applied Sciences**, v. 2, n. 8, p. 1460, 31 jul. 2020. DOI: <https://doi.org/10.1007/s42452-020-03257-1>. Acesso em: 28 nov. 2020.

CUNHA, T.J.F.; BLANCANEUX, P.; CALDERANO FILHO, B.; CARMO, C. A. F. S.; GARCIA, N. C. P.; LIMA, E. M. B. Influência da diferenciação pedológica no desenvolvimento da seringueira no município de Oratórios, MG. **Pesquisa Agropecuária Brasileira**, v.35, p.145-155, 2000. DOI: <https://doi.org/10.1590/S0100-204X2000000100017>. Acesso em 19 mai. 2020.

D'ANDRIMONT, R.; TAYMANS, M.; LEMOINE, G.; CEGLAR, A.; YORDANOV, M.; VAN DER VELDE, M. Detecting flowering phenology in oil seed rape parcels with Sentinel-1 and -2 time series. **Remote Sensing of Environment**, v. 239, p. 111660, mar. 2020. DOI: <https://doi.org/10.1016/j.rse.2020.111660>. Acesso em: 20 ago. 2020.

DECRAEMER, W.; HUNT, D. J. Structure and classification. **Plant nematology**. [S. l.]: CABI, 2013. p. 3–39. Disponível em: <http://hdl.handle.net/1854/LU-3127464>. Acesso em: 4 dez. 2020.

DEFOURNY, P.; BONTEMPO, S.; BELLEMANS, N.; CARA, C.; DEDIEU, G.; GUZZONATO, E.; HAGOLLE, O.; INGLADA, J.; NICOLA, L.; RABAUTE, T.; SAVINAUD, M.; UDROIU, C.; VALERO, S.; BÉGUÉ, A.; DEJOUX, J.-F.; EL HARTI, A.; EZZAHAR, J.; KUSSUL, N.; LABBASSI, K.; KOETZ, B. Near real-time agriculture monitoring at national scale at parcel resolution: Performance assessment of the Sen2-Agri automated system in various cropping systems around the world. **Remote Sensing of Environment**, v. 221, p. 551–568, fev. 2019. DOI: <https://doi.org/10.1016/j.rse.2018.11.007>. Acesso em: 16 mar. 2019.

DEKA, J.; KALITA, S.; KHAN, M. L. Vegetation Phenological Characterization of Alluvial Plain Shorea robusta-dominated Tropical Moist Deciduous Forest of Northeast India Using MODIS NDVI Time Series Data. **Journal of the Indian Society of Remote Sensing**, v. 47, n. 8, p. 1287–1293, 1 ago. 2019. DOI: <https://doi.org/10.1007/s12524-019-00991-x>. Acesso em: 11 dez. 2019.

DE WAELE, D. Foliar nematodes: Aphelenchoides species. In: STARR, J. L.; COOK, R.; BRIDGE, J. (ed). **Plant Resistance to Parasitic Nematodes**. CAB International, Wallingford, UK., 2002. pp. 141-151.

DINARDO-MIRANDA, L. L.; FRACASSO, J. V.; MIRANDA, I. D. Damage caused by *Meloidogyne javanica* and *Pratylenchus zae* to sugarcane cultivars. **Summa Phytopathologica**, v. 45, n. 2, p. 146–156, abr. 2019. DOI: <https://doi.org/10.1590/0100-5405/187782>. Acesso em: 07 fev. 2020.

DRUSCH, M.; DEL BELLO, U.; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P.; MEYGRET, A.; SPOTO, F.; SY, O.; MARCHESI, F.; BARGELLINI, P. Sentinel2: ESA's optical high-resolution mission for GMES operational services. **Remote sensing of Environment**, v. 120, n. sp-1322/2, p. 25–36, maio 2012. DOI: <https://doi.org/10.1016/j.rse.2011.11.026>. Acesso em: 22 mar. 2019.

DUARTE, D. M.; SILVA, C. R.; LEMES, E. M.; COELHO, L.; RODRIGUES, F. Analysis of Infestation of Nematode *Meloidogyne exigua* in a Rubber Tree Plantation in the Triângulo Mineiro Region. **Floresta e Ambiente**, v. 26, n. 4, 2019. DOI: [10.1590/2179-8087.036717](https://doi.org/10.1590/2179-8087.036717). Acesso em: 7 fev. 2020.

ECKERT, S.; HÜSLER, F.; LINIGER, H.; HODEL, E. Trend analysis of MODIS NDVI time series for detecting land degradation and regeneration in Mongolia. **J. Arid Environ.** 113, 16–28, 2015. DOI: <https://doi.org/10.1016/j.jaridenv.2014.09.001>. Acesso em: 21 fev. 2019.

EOS – Earth Observing System. NDVI FAQ: All you need to know about index. 2019. Disponível em <https://eos.com/blog/ndvi-faq-all-you-need-to-know-about-ndvi/>. Acesso em 15 outubro 2020.

EL-BATAL, A. I.; ATTIA, M. S.; NOFEL, M. M.; EL-SAYYAD, G. S. Potential Nematicidal Properties of Silver Boron Nanoparticles: Synthesis, Characterization, In Vitro and *in vivo* Root-Knot Nematode (*Meloidogyne incognita*) Treatments. **Journal of Cluster Science**, v. 30, n. 3, p. 687–705, 1 maio 2019. DOI: <https://doi.org/10.1007/s10876-019-01528-5>. Acesso em: 15 nov. 2019.

EMBRATER - EMPRESA BRASILEIRA DE ASSISTÊNCIA TÉCNICA E EXTENSÃO RURAL. **Manual técnico cultura da seringueira: norte**. Brasília, DF: EMBRATER, 1981.

ESCOLÀ, A.; MARTÍNEZ-CASASNOVAS, J. A.; RUFAT, J.; ARNÓ, J.; ARBONÉS, A.; SEBÉ, F.; PASCUAL, M.; GREGORIO, E.; ROSELL-POLO, J. R. Mobile terrestrial laser scanner applications in precision fruticulture/horticulture and tools to extract information from canopy point clouds. **Precision Agriculture**, v. 18, n. 1, p. 111–132, 1 fev. 2017. DOI: <https://doi.org/10.1007/s11119-016-9474-5>. Acesso em: 11 mai. 2019.

FORTUNER, R. On the morphology of *Aphelenchoides besseyi* Christie, 1942 and *A. siddiqii* n. sp. (Nematoda, Aphelenchoidea). **Journal of Helminthology** 44, 141-152, 1970.

FRANCISCO, V.L.F.S.; BUENO, C.R.F.; BAPTISTELLA, C.S.L. A cultura da seringueira no estado de São Paulo. **Informações Econômicas**, São Paulo, v.34, n.9, 2004. IAC. A importância da borracha natural. 2012. Disponível em: <http://iac.impulsohost.com.br/areasdepesquisa/seringueira/importancia.php/>. Acesso em: 10 fev. 2020.

FREIRE, F. C. O. Nematóides da região amazônica I – Nematóides parasitas e de vida livre associados a seringueira (*Hevea brasiliensis* Muell. Arg.) e ao guaraná (*Paullinia cupana* H.B.K. var. *sorbilis* (Mart.) Ducke). **Acta Amazônica**, Manaus, v.4, n.4, p. 401-404, 1976.

GAO, F.; ANDERSON, M.; DAUGHTRY, C.; KARNIELI, A.; HIVELEY, D.; KUSTAS, W. A within-season approach for detecting early growth stages in corn and soybean using high temporal and spatial resolution imagery. **Remote Sensing of Environment**, v. 242, p. 111752, jun. 2020. DOI: <https://doi.org/10.1016/j.rse.2020.111752>. Acesso em: 20 out. 2020.

GASCON, F.; BOUZINAC, C.; THÉPAUT, O.; JUNG, M.; FRANCESCONI, B.; LOUIS, J.; LONJOU, V.; LAFRANCE, B.; MASSERA, S.; GAUDEL-VACARESSE, A.; LANGUILLE, F.; ALHAMMOUD, B.; VIALLEFONT, F.; PFLUG, B.; BIENIARZ, J.; CLERC, S.; PESSIOT, L.; TRÉMAS, T.; CADAU, E.; BONIS, R.;

ISOLA, C.; MARTIMORT, P.; FERNANDEZ, V. Copernicus Sentinel-2A Calibration and Products Validation Status. **Remote Sensing**, v. 9, n. 6, p. 584, 10 jun. 2017. DOI: <https://doi.org/10.3390/rs9060584>. Acesso em: 07 jun. 2020.

GASPAROTTO, L.; PEREIRA, J. C. R.; MOREIRA, A.; FURTADO, E. L.; SANTOS, A. F. **Manual de identificação de doenças da cultura da seringueira**. Brasília, DF: EMBRAPA, 2016. 64 p.

GERAERT, E. The Pratylenchidae of the World: Identification of the family Pratylenchidae (Nematoda: Tylenchida). Academia Press, Gent, Belgium. 2013.

GOELDI, E. A. Relatório sobre a moléstia do cafeeiro na província do Rio de Janeiro. **Arquivos do Museu Nacional**, Rio de Janeiro, 1892.

GOOGLE EARTH. 2019. Disponível em: <https://earth.google.com/web/@-19.34526414,-49.04636962,625.8248527a,2407.49785265d,35y,0h,0t,0r>. Acesso em: 18 jul. 2020.

GONÇALVES, E.C.P. **A cultura da seringueira para o estado de São Paulo**. Campinas: 2010. 163p

GONÇALVES, P. S.; MARTINS, A. L. M.; FURTADO, E. L.; SAMBUGARO, R.; OTTATI, E. L.; ORTOLANI, A. A.; GODOY JÚNIOR, G. Desempenho de clones de seringueira da série IAC 300 na região do planalto de São Paulo. **Pesquisa Agropecuária Brasileira**, v. 37, nº 2, p.131-138, 2002.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18-27, 2017. DOI: <https://doi.org/10.1016/j.rse.2017.06.031>. Acesso em: 03 fev. 2020.

GROOVER, W. L.; LAWRENCE, K. S. Plant health evaluations of *Belonolaimus longicaudatus* and *Meloidogyne incognita* colonized bermudagrass using remote sensing. **Journal of Nematology**, v. 52, p. 1–13, 2020. DOI: <https://doi.org/10.21307/jofnem-2020-109>. Acesso em: 19 mai. 2020.

GUERREIRO, J. C.; OTOBONI, C. E. M.; BUSOLI, A. C. Agricultura de precisão no contexto do manejo integrado de pragas. In: BUSOLI, A.C.; GRIGOLLI, J. F. J.; SOUZA, L. A.; KUBOTA, M. M.; COSTA, E. N.; SANTOS, L. A. O.; NETTO, J. C.; VIANA, M. A. (ed.) **Tópicos em entomologia agrícola V**. Jaboticabal: Gráfica Multipress Ltda., 2012. p.135-150.

HAAG, H.P.; DECHEN, A.R.; SARRUGE, J.R.; GUERRINI, I.A.; WERBER, H.; TENPRIO, Z. **Nutrição mineral da seringueira**: marcha de absorção de nutrientes. Campinas: Fundação Cargill, 1982. 86p.

HIRD, J. N.; DELANCEY, E. R.; MCDERMID, G. J.; KARIYEVA, J. Google Earth Engine, Open-Access Satellite Data, and Machine Learning in Support of Large-Area Probabilistic Wetland Mapping. **Remote Sensing**, v. 9, n. 12, p. 1315, dez. 2017. DOI: <https://doi.org/10.3390/rs9121315>. Acesso em: 02 mar. 2020.

HODDA, M.; COLLINS, S. J.; VANSTONE, V. A.; HARTLEY, D.; WANJURA, W.; KEHOE, M. *Pratylenchus quasitereoides* n. sp. from cereals in Western Australia. *Zootaxa* v. 3866, n.2, p. 277-288. 2014. DOI: 10.5281/zenodo.230850. Acesso em: 5 mar. 2020.

HU, Y.; DONG, Y.; BATUNACUN. An automatic approach for land-change detection and land updates based on integrated NDVI timing analysis and the CVAPS method with GEE support. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 146, p. 347–359, 1 dez. 2018. DOI: <https://doi.org/10.1016/j.isprsjprs.2018.10.008>. Acesso em: 12 mai. 2019.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo Brasileiro de 2010**. Rio de Janeiro: IBGE, 2012. Disponível em: <https://cidades.ibge.gov.br/brasil/mg/prata/panorama>. Acesso em: 16 set. 2020.

IEA - INSTITUTO DE ECONOMIA AGRÍCOLA. Previsões e Estimativas das Safras Agrícolas do Estado de São Paulo, 2º Levantamento, Ano Agrícola 2017/18 e Levantamento Final, Ano Agrícola 2016/17, Novembro de 2017. **Análises e Indicadores do Agronegócio**, v. 13, n. 2, 2018.

IEA - INSTITUTO DE ECONOMIA AGRÍCOLA. Previsões e Estimativas das Safras Agrícolas do Estado de São Paulo, Ano Agrícola 2019/20 e Levantamento de junho, Ano Agrícola 2019/20, Junho de 2020. **Análises e Indicadores do Agronegócio**, v. 15, n. 9, 2020.

INT, C. **Green synthesis of sulfur nanoparticles using *Rosmarinus officinalis* leaves extract and nematicidal activity against *Meloidogyne javanica***. preprint. [S. l.]: Arabixiv, 9 dez. 2019. DOI: 10.31221/osf.io/vawz8. Acesso em: 26 nov. 2020.

JANSSEN, T.; KARSSSEN, G.; ORLANDO, V.; SUBBOTIN, S. A.; BERT, W. Molecular characterization and species delimiting of plant-parasitic nematodes of the genus *Pratylenchus* from the *penetrans* group (Nematoda: Pratylenchidae). **Molecular Phylogenetics and Evolution**, v. 117, p. 30–48, dez. 2017. DOI: <https://doi.org/10.1016/j.ympev.2017.07.027>. Acesso em: 22 mar. 2019.

JARAMILLO-GIRALDO, C.; FERREIRA, W. P. M.; FONSECA, H. P.; RIBEIRO, M. de F.; SILVA, L. M. R.; FERNANDES, R. B. A. Relationship Between Spatio-Temporal Leaf Area Index and Crop Coefficient When Monitoring Coffee Plots in Brazil. 2019. Disponível em: <http://www.alice.cnptia.embrapa.br/handle/doc/1116841>. Acesso em: 2 dez. 2020.

JIA, M.; WANG, Z.; WANG, C.; MAO, D.; ZHANG, Y. A New Vegetation Index to Detect Periodically Submerged Mangrove Forest Using Single-Tide Sentinel-2 Imagery. **Remote Sensing**, v. 11, n. 17, p. 2043, jan. 2019. DOI: <https://doi.org/10.3390/rs11172043>. Acesso em: 27 ago. 2020.

JONES, J. T.; HAEGEMAN, A.; DANCHIN, E. G. J.; GAUR, H. S.; HELDER, J.; JONES, M. G. K.; KIKUCHI, T.; MANZANILLA-LÓPEZ, R.; PALOMARES-RIUS, J. E.; WESEMAEL, W. M. L.; PERRY, R. N. Top 10 plant-parasitic nematodes in molecular plant pathology. **Molecular Plant Pathology**, v. 14, n. 9, p. 946–961, 2013. DOI: <https://doi.org/10.1111/mpp.12057>. Acesso em: 13 fev. 2020.

JONES, MGK., AND FOSU-NYARKO, J. Molecular biology of root lesion nematodes (*Pratylenchus* spp.) and their interaction with host plants. **Ann Appl Biol** 164, 163–181, 2014

JUNG, Y.-Y.; KIM, S.-W. A Study on the UAV-based Vegetable Index Comparison for Detection of Pine Wilt Disease Trees. **Journal of Cadastre & Land InformatiX**, v. 50, n. 1, p. 201–214, 2020. DOI: <https://doi.org/10.22640/lxsiri.2020.50.1.201>. Acesso em: 12 nov. 2020.

KITAMURA, M.C. **Heveicultura em Mato Grosso do Sul**. Campo Grande: EMPAER, 1989. 24 p.

KOWALSKI, K.; SENF, C.; HOSTERT, P.; PFLUGMACHER, D. Characterizing spring phenology of temperate broadleaf forests using Landsat and Sentinel-2 time series. **International Journal of Applied Earth Observation and Geoinformation**, v. 92, p. 102172, 1 out. 2020. DOI: <https://doi.org/10.1016/j.jag.2020.102172>. Acesso em: 12 nov. 2020.

KRISHNAN, A.; JOSEPH, L.; ROY, C. B. insight into Hevea - Phytophthora interaction: The story of Hevea defense and Phytophthora counter defense mediated through molecular signalling. **Current plant biology**, 2019. Disponível em: <https://agris.fao.org/agris-search/search.do?recordID=US201900433668>. Acesso em: 02 jan. 2020.

LANDIS, J. R.; KOCH, G. G. The Measurement of Observer Agreement for Categorical Data. **Biometrics**, v. 33, n. 1, p. 159–174, 1977. DOI: <https://doi.org/10.2307/2529310>. Acesso em: 07 jul. 2020.

LE, K. D. **Incidence and pathogenicity of plant-parasitic nematodes on coffee in Australia and the potential of organic amendments as a management tactic**. 2020. Thesis – University of Sydney, 2020. Disponível em: <https://ses.library.usyd.edu.au/handle/2123/23277>. Acesso em: 20 nov. 2020.

LEMES, E. M.; MACHADO, T. V.; GONTIJO, L. N.; DE ANDRADE, S. L.; TORRES, J. L. R.; SANTOS, M. A.; COELHO, L. Detection of rubber tree orchards infested by *Meloidogyne exigua* using vegetation indexes obtained from satellite images. **New Forests**, v. 51, n. 5, p. 765–779, 2020. DOI: <https://doi.org/10.1007/s11056-019-09760-7>. Acesso em: 7 fev. 2020.

LEMOS FILHO, J.P. **Aspectos fisiológicos e biometeorológicos relacionados com a técnica de mini-enxertia da seringueira (*Hevea spp*)**. (Doutorado na área de Ciências) – Instituto de Ciências Biológicas, Universidade Estadual de Campinas, Campinas, São Paulo. 1991. 1260. Disponível em: http://repositorio.unicamp.br/jspui/bitstream/REPOSIP/315132/1/LemosFilho_JosePires_de_D.pdf. Acesso em: 27 jun. 2019.

LEÓN, J, 1987. Fundamento botánico de los cultivos tropicales. San José, Costa Rica. **Instituto Interamericano de Ciencias Agrarias**. 487 pág.

LIANG, C.; ZHANG, X.; XU, J.; PAN, G.; WANG, Y. An integrated framework to select resilient and sustainable sponge city design schemes for robust decision making.

- Ecological Indicators**, v. 119, p. 106810, 1 dez. 2020. DOI: <https://doi.org/10.1016/j.ecolind.2020.106810>. Acesso em: 08 dez. 2020.
- LI, Y.; LAN, G.; XIA, Y. Rubber Trees Demonstrate a Clear Retranslocation Under Seasonal Drought and Cold Stresses. **Frontiers in Plant Science**, v. 7, 2016. DOI: 10.3389/fpls.2016.01907. Acesso em: 25 nov. 2020.
- LORENZI, H. **Árvores brasileiras: manual de identificação e cultivo de plantas arbóreas nativas do Brasil**. Nova Odessa, SP: Instituto Plantarum, 2002. v. 1. 368 p.
- LUO, Y.; ZHANG, Z.; CHEN, Y.; LI, Z.; TAO, F. ChinaCropPhen1km: a high-resolution crop phenological dataset for three staple crops in China during 2000–2015 based on leaf area index (LAI) products. **Earth System Science Data**, v. 12, n. 1, p. 197–214, 31 jan. 2020. DOI: <https://doi.org/10.5194/essd-12-197-2020>. Acesso em: 25 nov. 2020.
- MACHADO, T. V. **Alterações de componentes silviculturais e de produção de *Hevea brasiliensis* causados por *Meloidogyne exigua***. 2018. Dissertação (Mestrado em Fitopatologia) Universidade Federal de Uberlândia, Uberlândia. 2018 DOI 10.14393/ufu.di.2018.732. Acesso em: 9 nov. 2020.
- MAGNUSSON, C.; HOLGADO, R.; DAVIES, K. G.; DELIANG, P.; TANGVIK, M. P.; BURUD, I. Patch dynamics for studies on nematode pathogenicity and reproductive rates using UAVs in Norway. **Aspects of Applied Biology**, n. No.135, p. 65–71, 2017.
- MAHLEIN, A.-K.; KUSKA, M. T.; THOMAS, S.; BOHNENKAMP, D.; ALISAAC, E.; BEHMANN, J.; WAHABZADA, M.; KERSTING, K. Plant disease detection by hyperspectral imaging: from the lab to the field. **Advances in Animal Biosciences**, v. 8, n. 2, p. 238–243, jul. 2017. DOI: <https://doi.org/10.1017/S2040470017001248>. Acesso em: 23 abr. 2020.
- MARQUES, P. C.; GONÇALVES, P. S.; GALVEAS, P. A. O. **Seringueira Clones - 2007: 2ª Recomendação para o Estado do Espírito Santo**. 2ª ed. Vitória-ES: Dcm-incaper, 2007. Acesso em: 08 out. 2019.
- MARTINS, G. D.; GALO, M. L. B. T.; VIEIRA, B. S. 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**, v. 10, n. 12, p. 5395–5403, dez. 2017. DOI: <https://doi.org/10.1109/JSTARS.2017.2737618>. Acesso em: 28 jun. 2020.
- MEDRADO, M. J. S.; BERNARDES, M. S.; COSTA, J. D.; MARTINS, A. N. **Formação de mudas e plantio de seringueira**. Piracicaba, SP: ESALQ – Departamento de Agricultura, 1992. 158p.
- MULLA, D. J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, v. 114, n. 4, p. 358–371, abr. 2013. DOI: <https://doi.org/10.1016/j.biosystemseng.2012.08.009>. Acesso em: 18 fev. 2019.

MUNIZ, M. F. S.; CAMPOS, V. P.; ALMEIDA, M. R. A.; GOMES, A. C. M. M.; DOS SANTOS, M. F.; DE CASTRO MOTA, F.; CARNEIRO, R. M. D. G. Additional information on an atypical population of *Meloidogyne exigua* Goldi, 1887 (Tylenchida: Meloidogynidae) parasitizing rubber tree in Brazil. **Nematology**, Leiden, v. 11, p. 95106, 2009. Acesso em: 18 nov. 2019.

MUTANGA, O.; KUMAR, L. Google Earth Engine Applications. **Remote Sensing**, v. 11, n. 5, p. 591, 12 mar. 2019. DOI: <https://doi.org/10.3390/rs11050591>. Acesso em: 30 jan. 2020.

NASRALLAH, A.; BAGHDADI, N.; EL HAJJ, M.; DARWISH, T.; BELHOUCLETTE, H.; FAOUR, G.; DARWICH, S.; MHAWAJ, M. Sentinel-1 Data for Winter Wheat Phenology Monitoring and Mapping. **Remote Sensing**, v. 11, n. 19, p. 2228, 25 set. 2019. DOI: <https://doi.org/10.3390/rs11192228>. Acesso em: 13 out. 2020.

NIU, H.; ZHAO, T.; WESTPHAL, A.; CHEN, Y. A low-cost proximate sensing method for early detection of nematodes in walnut using Walabot and scikit-learn classification algorithms. *In: Anais. In: PROC SPIE*. 21 abr. 2020. DOI: <https://doi.org/10.1117/12.2558214>. Acesso em: 17 nov. 2020.

NOMURA, K.; MITCHARD, E. T. A. More Than Meets the Eye: Using Sentinel-2 to Map Small Plantations in Complex Forest Landscapes. **Remote Sensing**, v. 10, n. 11, p. 1693, nov. 2018. DOI: <https://doi.org/10.3390/rs10111693>. Acesso em: 21 abr. 2020.

NOURI, H.; ANDERSON, S.; SUTTON, P.; BEECHAM, S.; NAGLER, P.; JARCHOW, C. J.; ROBERTS, D. A. NDVI, scale invariance and the modifiable areal unit problem: An assessment of vegetation in the Adelaide Parklands. **Science of The Total Environment**, v. 584–585, p. 11–18, abr. 2017. DOI: <https://doi.org/10.1016/j.scitotenv.2017.01.130>. Acesso em: 20 mai. 2020.

NZIMANDE, N.; MUTANGA, O.; KIALA, Z.; SIBANDA, M. Mapping the spatial distribution of the yellowwood tree (*Podocarpus henkelii*) in the Weza-Ngele forest using the newly launched Sentinel-2 multispectral imager data. **South African Geographical Journal**, v. 0, n. 0, p. 1–19, 16 fev. 2020. DOI: <https://doi.org/10.1080/03736245.2020.1722211>. Acesso em 13 nov. 2020.

OLIVEIRA, C.J., SUBBOTIN, S.A., ÁLVAREZ-ORTEGA, S., DESAEGER, J., BRITO, J.A., XAVIER, K.V., FREITAS, L.G., VAU, S.; INSERRA, R.N. Morphological and molecular identification of two Florida populations of foliar nematodes (*Aphelenchoides* spp.) isolated from strawberry with the description of *Aphelenchoides pseudogoodeyi* sp. n. (Nematoda: Aphelenchoididae) and notes on their bionomics. **Plant Disease** 103, 2825- 2842. 2019. DOI: 10.1094/PDIS-04-19-0752-RE. Acesso em: 18 abr. 2020.

OLIVEIRA, G. F.; SILVA, M. S.; PROENÇA, S. L.; BOSSOLANI, J. W.; CAMARGO, J.; FRANCO, F.; SÁ, M. E. Influência do *Bacillus subtilis* no controle biológico de nematoides e aspectos produtivos do feijoeiro / Influence of *Bacillus subtilis* in nematodes biological control and production aspects of bean. 2017. [S. l.: s. n.], 2017. DOI: <https://doi.org/10.18011/BIOENG2017V11N1P47-58>. Acesso em: 20 nov. 2019.

OLIVEIRA, G. H. F.; SANTANA, S. R. A.; FONSECA, R. C. N.; LIMA, L. E. de; GOMES, L. A. A.; FILHO, J. L. S. C. Meloidogyne incognita resistant strains of leaf lettuce. **African Journal of Agricultural Research**, v. 10, n. 51, p. 4660–4667, 17 dez. 2015. DOI: <https://doi.org/10.5897/AJAR2015.9696>. Acesso em: 10 jan. 2019.

OLIVEIRA, K. C. L.; ARAÚJO, D. V.; MENESES, A. C.; SILVA, J. M.; TAVARES, R. L. C.; OLIVEIRA, K. C. L.; ARAÚJO, D. V.; MENESES, A. C.; SILVA, J. M.; TAVARES, R. L. C. Biological management of *Pratylenchus brachyurus* in soybean crops. **Revista Caatinga**, v. 32, n. 1, p. 41–51, mar. 2019. DOI: <https://doi.org/10.1590/1983-21252019v32n105rc>. 24 fev. 2020.

ORTOLANI, A.A.; PEDRO JUNIOR, M.J.; ALFONSI, R.R.; CAMARGO, M.B.P.; BRUNINI, O. Aptidão agrícola para regionalização da heveicultura no Brasil. In: SEMINÁRIO BRASILEIRO SOBRE RECOMENDAÇÕES DE CLONES DE SERINGUEIRA, 1 Brasília, 1982. **Anais**, p. 19-28.

PAES-TAKAHASHI, V. S.; SOARES, P. L. M.; SOARES, E. P. M.; BRITO, P. F.; CARNEIRO, F. A.; FERREIRA JUNIOR, R. Reação de porta-enxertos de seringueira a *Meloidogyne exigua* e a *Pratylenchus brachyurus*. **Nematropica**, v. 45, n. 2, p. 242–251, 1 dez. 2015. Disponível em: <http://journals.fcla.edu/nematropica/article/view/87385/84218>. Acesso em: 25 fev. 2018.

PAES-TAKAHASHI, V. S.; SOARES, P. L. M.; BRITO, P. F.; CARNEIRO, F. A.; SANTOS, J. M. Ocorrência de nematoides em viveiros de produção de mudas de seringueira no estado de São Paulo. **Nematropica**, v. 46, n. 2, p. 132–137, 1 dez. 2016. Disponível em: <https://journals.flvc.org/nematropica/article/view/90791>. Acesso em: 25 fev. 2018.

PALOMARES-RIUS, J. E.; GUESMI, I.; HORRIGUE-RAOUANI, N.; CANTALAPIEDRA-NAVARRETE, C.; LIÉBANAS, G.; CASTILLO, P. Morphological and molecular characterisation of *Pratylenchus oleae* n. sp. (Nematoda: Pratylenchidae) parasitizing wild and cultivated olives in Spain and Tunisia. **European Journal of Plant Pathology**, v. 140, n. 1, p. 53–67, set. 2014. DOI: <https://doi.org/10.1007/s10658-014-0443-4>. Acesso em: 28 jun. 2020.

PEZZONI FILHO, J. C. **Dinâmica espaço-temporal da ocorrência de nematoides em seringueira**. 2014. 125 f. Tese (doutorado) - Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Ciências Agrônômicas de Botucatu, Botucatu. 2014. Disponível em: <http://hdl.handle.net/11449/132170>. Acesso em: 18 jun. 2018.

PEZZONI FILHO, J. C.; BRIDA, A. L. de; MORAES, D. A. de C.; ZIMBACK, C. R. L.; WILCKEN, S. R. S.; FURTADO, E. L. *Meloidogyne exigua* (Meloidogynidae) em clones de seringueira em duas épocas do ano. **Ciencia & Tecnología Agropecuaria**, v. 19, n. 3, 22 ago. 2018. DOI: 10.21930/rcta.vol19_num3_art:566. Disponível em: <http://revistacta.agrosavia.co/index.php/revista/article/view/566>. Acesso em: 26 fev. 2020.

POORTINGA, A.; TENNESON, K.; SHAPIRO, A.; NQUYEN, Q.; SAN AUNG, K.; CHISHTIE, F.; SAAH, D. Mapping Plantations in Myanmar by Fusing Landsat-8, Sentinel-2 and Sentinel-1 Data along with Systematic Error Quantification. **Remote Sensing**, v. 11, n. 7, p. 831, jan. 2019. DOI: <https://doi.org/10.3390/rs11070831>. Acesso

em: 30 abr. 2020.

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

PRIYADARSHAN, P. M. Breeding *Hevea brasiliensis* for environmental constraints. **Advances in Agronomy**. Academic Press, 2003. v. 79, p. 351–400. Disponível em: <http://www.sciencedirect.com/science/article/pii/S006521130279007X>. Acesso em: 07 jun. 2020.

PRIYADARSHAN, P. M. Refinements to *Hevea* rubber breeding. **Tree Genetics & Genomes**, v. 13, n. 1, p. 20, fev. 2017. DOI: <https://doi.org/10.1007/s11295-017-1101-8>. Acesso em 14 mar. 2018.

QIN, L.; WANG, X.; JIANG, J.; YANG, X.; KE, D.; LI, H.; WANG, D. Use hyperspectral remote sensing technique to monitoring pine wood nomatode disease preliminary. *In: Anais... In: PROC SPIE*. 25 out. 2016. DOI: <https://doi.org/10.1117/12.2247214>. Acesso em: 17 nov. 2020.

RAMAMOORTHY, V.; VISWANATHAN, R.; RAGUCHANDER, T.; PRAKASAM, V.; SAMIYAPPAN, R. Induction of systemic resistance by plant growth promoting rhizobacteria in crop plants against pests and diseases. **Crop Protection**, v. 20, n. 1, p. 1–11, fev. 2001. DOI: [https://doi.org/10.1016/S0261-2194\(00\)00056-9](https://doi.org/10.1016/S0261-2194(00)00056-9). Acesso em: 24 abr. 2018.

RASHID, F.; GERAERT, E.; SHARMA, R. D. The genus *Peltamigratus* Sher, 1964 with description of two new species (Nematoda: Tylenchida). **Revue de Nématologie**, v.10, n.1, p.3-21, 1987.

RECANATESI, F.; PICCINNO, M.; CUCCA, B.; ROSSI, C. M.; RIPA, M. N. The Contribution of Remote Sensing and Silvicultural Treatments to the Assessment of Decline in an Oak Deciduous Forest: The Study Case of a Protected Area in Mediterranean Environment. 2020. **Computational Science and Its Applications – ICCSA 2020** [...]. Cham: Springer International Publishing, 2020. p. 36–49. DOI: https://doi.org/10.1007/978-3-030-58814-4_3. Acesso em: 23 out. 2020.

RIVA, M.J.; DALIAKOPOULOS, I.N.; ECKERT, S.; HODEL, E.; LINIGER, H. Assessment of land degradation in Mediterranean forests and grazing lands using a landscape unit approach and the normalized difference vegetation index. **Appl. Geogr.** 86, 8–21, 2017. DOI: <https://doi.org/10.1016/j.apgeog.2017.06.017>. Acesso em: 30 jul. 2020.

ROUSE, J. W., HAAS, R. H., SCHELL, J. A., DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In Proceedings of the Third ERTS Symposium, 1:309–317. 1973. Disponível em: <https://ntrs.nasa.gov/api/citations/19740022614/downloads/19740022614.pdf>. Acesso em: 13 out. 2020.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN, J. C. Monitoring the vernal advancement and retrogradation (greenwave effect) of natural

vegetation [Technical report]. NASA. 1974. Disponível em:
<https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19750020419.pdf>. Acesso em: 13 out. 2020.

SÃO PAULO. Coordenadoria de Defesa Agropecuária do Estado de São Paulo. Resolução SAA - 154, DE 22-11-2013. Estabelece exigências para cadastramento de viveiros, jardins clonais, plantas matrizes produtoras de sementes e normas técnicas de defesa sanitária vegetal, para a produção, comércio e o transporte de mudas, borbulhas e sementes de seringueira (*hevea* spp) no Estado de São Paulo. Disponível em:
<http://www.defesaagropecuaria.sp.gov.br> . Acesso em: 26 jun. 2019.

SANTIN-JANIN, H.; GAREL, M.; CHAPUIS, J.-L.; PONTIER, D. Assessing the performance of NDVI as a proxy for plant biomass using non-linear models: a case study on the Kerguelen archipelago. **Polar Biology**, v. 32, n. 6, p. 861–871, jun. 2009. DOI: <https://doi.org/10.1007/s00300-009-0586-5>. Acesso em: 15 nov. 2020.

SANTOS, E. A.; VIANA, A. P.; FREITAS, J. C. O.; RODRIGUES, D. L.; TAVARES, R. F.; PAIVA, C. L.; SOUZA, M. M. Genotype selection by REML/BLUP methodology in a segregating population from an interspecific *Passiflora* spp., crossing. **Euphytica** 204: 1-11, 2015. DOI: <https://doi.org/10.1007/s10681-015-1367-6>. Acesso em: 12 abr. 2020.

SCALLOPI JUNIOR, E. J. Seringueira: panorama, pesquisa e perspectiva de clones. **Pesquisa & Tecnologia**, v. 8, n. 47, set. 2011. Disponível em <
<http://www.aptaregional.sp.gov.br>. Acesso em: 10 jun. 2012

SCHULTES, R. E. Studies in the genus *Hevea*. VIII. Notes on infraspecific variants of *Hevea brasiliensis* (Euphorbiaceae). **Economic Botany**, 41(2), p. 125- 147. 1987. DOI: <https://doi.org/10.1007/BF02858960>. Acesso em: 12 out. 2020.

SHARMA, R.D.; EKHARDT, R. Incidência de nematoides fitoparasitas no Estado do Amazonas. **Fitopatologia Brasileira**, Brasília, DF, v. 4, n. 1,1979.

SHARMA, R.D.; LOOF, P.A.A. Nematode of the cocoa region of Bahia, Brazil I – Plant – Parasitic and free – living nematodes associated with rubber (*Hevea brasiliensis* Muell. Arg). **Revista Theobroma** 3:36-41. 1973.

SHARMA, R.D. Nematodes of the cocoa region of the State of Espírito Santo, Brazil: II. Nematodes associated with field crops and forest trees. **Revista Theobroma**, Ilhéus, v.6, n.4, 1976.

SHARMA, R. D.; JUNQUEIRA, N. T. V. Pathogenicity of *Meloidogyne exigua* on *Hevea brasiliensis* root-stock. **Fitopatologia Brasileira**, Brasília, v. 21, p. 418, ago. 1996. Suplemento. Disponível em:
<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/211027/1/digitalizar0036.pdf>. Acesso em: 19 mai. 2020.

SHI-BO, F., XIN-SHI, Z. Control of vegetation distribution: climate, geological substrate, and geomorphic factors. A case study of grassland in Ordos, Inner Mongolia,

China. **Can. J. Remote Sens.** 39 (2), 167–174, 2013. DOI: <https://doi.org/10.5589/m13-022>. Acesso em: 19 jul. 2020.

SIDDIQUE, S.; GRUNDLER, F. M. Parasitic nematodes manipulate plant development to establish feeding sites. **Current Opinion in Microbiology**, Host Microbe Interactions: Fungi * Host Microbe Interactions: Parasitology. v. 46, p. 102–108, 1 dez. 2018. DOI: <https://doi.org/10.1016/j.mib.2018.09.004>. Acesso em: 05 fev. 2020.

SILVA, J.; VARELA, N.; LEZAMA, O. B. P. Multispectral Image Analysis for the Detection of Diseases in Coffee Production. 2021. **Distributed Computing and Artificial Intelligence, 17th International Conference** [...]. Cham: Springer International Publishing, 2021. p. 198–205. DOI: https://doi.org/10.1007/978-3-030-53036-5_21. Acesso em: 19 jul. 2020.

SINHA, S. K.; PADALIA, H.; DASGUPTA, A.; VERRELST, J.; RIVERA, J. P. Estimation of leaf area index using PROSAIL based LUT inversion, MLRA-GPR and empirical models: Case study of tropical deciduous forest plantation, North India. **International Journal of Applied Earth Observation and Geoinformation**, v. 86, p. 102027, 1 abr. 2020. DOI: <https://doi.org/10.1016/j.jag.2019.102027>. Acesso em: 10 jul. 2020.

SOUZA, E. C. de; COELHO, L.; LEMES, E. M.; GONTIJO, L. N.; SOUZA, E. C. de; COELHO, L.; LEMES, E. M.; GONTIJO, L. N. Manejo de *Meloidogyne exigua* em seringueira com produtos biológicos e químicos. **Summa Phytopathologica**, v. 45, n. 4, p. 406–412, out. 2019. DOI: <https://doi.org/10.1590/0100-5405/205581>. Acesso em: 27 out. 2020.

STENDARDI, L.; KARLSEN, S.; NIEDRIST, G.; GERDOL, R.; ZEBISCH, M.; ROSSI, M.; NOTARNICOLA, C. Exploiting Time Series of Sentinel-1 and Sentinel-2 Imagery to Detect Meadow Phenology in Mountain Regions. **Remote Sensing**, v. 11, n. 5, p. 542, 6 mar. 2019. DOI: <https://doi.org/10.3390/rs11050542>. Acesso em: 21 out. 2020.

SUBBOTIN, S. A.; OLIVEIRA, C. J.; ÁLVAREZ-ORTEGA, S.; DESAEGER, J. A.; CROW, W.; OVERSTREET, C.; LEAHY, R.; VAU, S.; INSERRA, R. N. The taxonomic status of *Aphelenchoides besseyi* Christie, 1942 (Nematoda: Aphelenchoididae) populations from the southeastern USA, and description of *Aphelenchoides pseudobesseyi* sp. n. **Nematology**, , p. 1–33, 8 set. 2020. DOI: <https://doi.org/10.1163/15685411-bja10048>. Acesso em: 12 nov. 2020.

SUBBOTIN, S.A., RAGSDALE, E.J., MULLENS, T., ROBERTS, P.A., MUNDO-OCAMPO, M.; BALDWIN, J.G. A phylogenetic framework for root lesion nematodes of the genus *Pratylenchus* (Nematoda): evidence from 18S and D2-D3 expansion segments of 28S ribosomal RNA genes and morphological characters. **Molecular Phylogenetics and Evolution** 48, 491-505, 2008. DOI: 10.1016/j.ympev.2008.04.028. Acesso em: 12 nov. 2020.

SUTTON, P.C., ANDERSON, S.J., COSTANZA, R., KUBISZEWSKI, I. The ecological economics of land degradation: impacts on ecosystem service values. **Ecol.**

- Econ.** 129, 182–192, 2016. DOI: <https://doi.org/10.1016/j.ecolecon.2016.06.016>. Acesso em: 14 out. 2020.
- TESTA, S.; SOUDANI, K.; BOSCHETTI, L.; BORGOGNO MONDINO, E. MODIS-derived EVI, NDVI and WDRVI time series to estimate phenological metrics in French deciduous forests. **International Journal of Applied Earth Observation and Geoinformation**, v. 64, p. 132–144, 1 fev. 2018. DOI: <https://doi.org/10.1016/j.jag.2017.08.006>. Acesso em: 17 nov. 2020.
- TIHOHOD, D. **Nematologia agrícola aplicada**. 2. ed. Jaboticabal: Funep, 2000.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, maio 1979. DOI: [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0). [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0). Acesso em: 04 out. 2020.
- TZOVARAS, D.; GIAKOUMIS, D.; VINCZE, M.; ARGYROS, A. (Orgs.). **Computer Vision Systems: 12th International Conference, ICVS 2019, Thessaloniki, Greece, September 23–25, 2019, Proceedings**. Cham: Springer International Publishing, 2019. v. 11754, (Lecture Notes in Computer Science). DOI: 10.1007/978-3-030-34995-0. Acesso em: 17 nov. 2020.
- VALLE JÚNIOR, R. F. do; SIQUEIRA, H. E.; VALERA, C. A.; OLIVEIRA, C. F.; SANCHES FERNANDES, L. F.; MOURA, J. P.; PACHECO, F. A. L. Diagnosis of degraded pastures using an improved NDVI-based remote sensing approach: An application to the Environmental Protection Area of Uberaba River Basin (Minas Gerais, Brazil). **Remote Sensing Applications: Society and Environment**, v. 14, p. 20–33, 1 abr. 2019. DOI: <https://doi.org/10.1016/j.rsase.2019.02.001>. Acesso em: 03 jan. 2020.
- VIERA-TORRES, M.; SINDE-GONZÁLEZ, I.; GIL-DOCAMPO, M.; BRAVO-YANDÚN, V.; TOULKERIDIS, T. Generating the Baseline in the Early Detection of Bud Rot and Red Ring Disease in Oil Palms by Geospatial Technologies. **Remote Sensing**, v. 12, n. 19, p. 3229, jan. 2020. DOI: <https://doi.org/10.3390/rs12193229>. Acesso em: 20 out. 2020.
- VILLAIN, L., LIMA SALGADO S.M., TRINH P.Q. Nematode parasites of coffee and cocoa In: SIKORA R. A.; COYNE d.; HALLMANN J.; TIMPER P. (Ed.) **Plant parasitic nematodes in subtropical and tropical agriculture**. Wallingford : CABI, p. 536-583. 2018.
- VOGELMANN, J. E.; XIAN, G.; HOMER, C.; TOLK, B. Monitoring gradual ecosystem change using Landsat time series analyses: Case studies in selected forest and rangeland ecosystems. **Remote Sensing of Environment**, v. 122, p. 92–105, jul. 2012. DOI: <https://doi.org/10.1016/j.rse.2011.06.027>. Acesso em: 09 out. 2020.
- VU, Q.M., LE, Q.B., FROSSARD, E., VLEK, P.L.G. Socio-economic and biophysical determinants of land degradation in Vietnam: an integrated causal analysis at the national level. **Land Use Policy** 36, 605–617. 2014. DOI: <https://doi.org/10.1016/j.landusepol.2013.10.012>. Acesso em: 22 abr. 2020.

WANG, H.; ZHUO, K.; YE, W.; LIAO, J. Morphological and molecular characterisation of *Pratylenchus parazeae* n. sp. (Nematoda: Pratylenchidae) parasitizing sugarcane in China. **European Journal of Plant Pathology**, v. 143, n. 1, p. 173–191, set. 2015. DOI: <https://doi.org/10.1007/s10658-015-0674-z>. Acesso em: 13 mai. 2020.

WARREN-THOMAS, E.; DOLMAN, P. M.; EDWARDS, D. P. Increasing Demand for Natural Rubber Necessitates a Robust Sustainability Initiative to Mitigate Impacts on Tropical Biodiversity: Rubber sustainability and biodiversity. **Conservation Letters**, v. 8, n. 4, p. 230–241, jul. 2015. DOI: <https://doi.org/10.1111/conl.12170>. Acesso em 12 out. 2020.

WEISCHER, B.; BROWN, D. J. F. **Conhecendo os nematoides**: nematologia geral. Sofia: Pensoft Publishers, 209 p., 2001.

WILCKEN, S. R. S.; GABIA, A. A.; BRITO, P. F.; FURTADO, E. L. Nematoides fitoparasitas em seringais do Estado de São Paulo. **Summa Phytopathologica**, v. 41, n. 1, p. 54–57, mar. 2015. DOI: <https://doi.org/10.1590/0100-5405/2025>. Acesso em: 13 mai. 2019.

WYSS, U.; GRUNDLER F. M. W.; MUNCH, A. The parasitic behaviour of second stage juveniles of *Meloidogyne incognita* in roots of *Arabidopsis thaliana*. **Nematologica** 38, 98–111, 1992. DOI: <https://doi.org/10.1163/187529292X00081>. Acesso em: 17 out. 2020.

WU, W.; ZHANG, Z.; ZHENG, L.; HAN, C.; WANG, X.; XU, J.; WANG, X. Research Progress on the Early Monitoring of Pine Wilt Disease Using Hyperspectral Techniques. **Sensors**, v. 20, n. 13, p. 3729, jan. 2020. DOI: <https://doi.org/10.3390/s20133729>. Acesso em: 02 mar. 2020.

WYCHERLEY, P. R. CHAPTER 3 - The Genus *Hevea* - Botanical Aspects. *In*: SETHURAJ, M. R.; MATHEW, N. M. (orgs.). **Developments in Crop Science**. Natural Rubber. [S. l.]: Elsevier, 1992. v. 23, p. 50–66. DOI: 10.1016/B978-0-444-88329-2.50009-X. Acesso em: 03 mar. 2020.

XIAO, C.; LI, P.; FENG, Z.; LIU, Y.; ZHANG, X. Sentinel-2 red-edge spectral indices (RESI) suitability for mapping rubber boom in Luang Namtha Province, northern Lao PDR. **International Journal of Applied Earth Observation and Geoinformation**, v. 93, p. 102176, dez. 2020. DOI: <https://doi.org/10.1016/j.jag.2020.102176>. Acesso em: 18 out. 2020.

YE, W. Nematodes of Agricultural Importance in North and South Carolina. *In*: SUBBOTIN, S. A.; CHITAMBAR, J. J. (orgs.). **Plant Parasitic Nematodes in Sustainable Agriculture of North America : Vol.2 - Northeastern, Midwestern and Southern USA**. Sustainability in Plant and Crop Protection. Cham: Springer International Publishing, 2018. p. 247–276. DOI: 10.1007/978-3-319-99588-5_10. Acesso em: 13 fev. 2020.

ZHOU, B.; OKIN, G. S.; ZHANG, J. Leveraging Google Earth Engine (GEE) and machine learning algorithms to incorporate *in situ* measurement from different times for rangelands monitoring. **Remote Sensing of Environment**, v. 236, p. 111521, 1 jan. 2020. DOI: <https://doi.org/10.1016/j.rse.2019.111521>. Acesso em: 12 mai. 2020.

ZURQANI, H. A.; POST, C. J.; MIKHAILOVA, E. A.; SCHLAUTMAN, M. A.; SHARP, J. L. Geospatial analysis of land use change in the Savannah River Basin using Google Earth Engine. **International Journal of Applied Earth Observation and Geoinformation**, v. 69, p. 175–185, jul. 2018. DOI: <https://doi.org/10.1016/j.jag.2017.12.006>. Acesso em: 13 mai. 2019.

APÊNDICES

Apêndice 1

Zonal Statistics

No processamento dos dados desse script é perceptível a função “print()” logo após cada etapa. O objetivo é imprimir o resultado de cada variável no console para simples conferência. Então procedeu-se: a entrada de dados, composta por Shapefile em formato de polígonos para representar as áreas com Seringueiras e outro em formato de pontos para caracterizar os locais de treinamento e resultado laboratorial quanto à presença de nematoides; definição do período de análise, correspondendo ao ano de 2019 (linhas 2 e 3); carregar os pontos de checagem (linha 6); definir o tamanho do raio do buffer (linha 9); definir a porcentagem máxima de nuvens (linha 12); carregar os polígonos das áreas com seringueira (linha 15); definir o código da cena e o número orbital (linhas 18 e 19); criar coleção de imagens do satélite Sentinel-2 (linhas 22 a 32); função para cálculo de NDVI e aplicação (linhas 35 e 36) e (linha 39); função para renomear as bandas da série temporal (linhas 44 e 45) e empilhamento da coleção de imagens (linha 48); recortar a imagem usando as áreas de interesse (linha 53); função para calcular buffer e aplicação (linhas 58 a 60) e (linha 62); cálculo da estatística zonal, que retorna o número de pixels, média e desvio padrão dentro de cada buffer (linhas 67 a 72); visualização dos dados (linhas 78 a 81); e, por fim, exportação dos dados em formato de planilha (linhas 84, 86, 88 a 93). A planilha foi então descarregada e usada no software IBM SPSS Statistics versão 20.

```

1  /*****
2  *          PARÂMETROS FIXOS
3  *****/
4
5  // Informar o período em análise
6  var data_inicial = ('2019-01-01');
7
8  var data_final = ('2019-12-31');
9
10 var regioao = ('Prata-MG') //ESPECIFICAR O MUNICÍPIO
11

```

```
12 //PONTOS DE CHECAGEM
13 var pontos = table
14
15 //Definir o raio do buffer em metros
16 var raio = 10
17
18 //Definir a porcentagem máxima de nuvem
19 var nuvem = 10
20
21 //informe o nome da área de interesse
22 var roi = table2
23
24
25 //Caso seja necessário descomente e insira o nome do TILE e ORBIT NUMBER
26 var MGRS_TILE = '22KGD';
27 var ON = 81;
28
29 var rename_band = function(img){
30     return img.select([0], [img.id()]);
31 };
32
33 /*
34 */
35 // Carrega Imagens Sentinel-2 BOA reflectance
36 var collection = ee.ImageCollection('COPERNICUS/S2_SR')
37     .filterDate(data_inicial, data_final)
38     //filtro por região
39     .filterBounds(roi)
40     // Filtro de Nuvens
41     .filter(ee.Filter.lte('CLOUDY_PIXEL_PERCENTAGE', nuvem))
42     .filterMetadata('SENSING_ORBIT_NUMBER', 'equals', ON)
43     .filterMetadata('MGRS_TILE', 'contains', MGRS_TILE)
44     //limit(35)
45     //.map(mask1);
```

```
46
47
48 // Function to calculate and add an NDVI band
49 var ndvi = function(image) {
50   return image.addBands(image.normalizedDifference(['B8', 'B4']));
51 };
52
53
54 // Add NDVI band to image collection
55 var ndvi = collection.map(ndvi);
56
57 print('sentinel ndvi', ndvi);
58
59 // renomeia NDVI
60 var rename_band_ndvi = function(img){
61   return img.select(['nd'], [img.id()]);
62 };
63
64
65 //renomeia ndvi
66 var coll = ndvi.map(rename_band_ndvi).toBands()
67
68 print('sentinel ndvi', coll)
69
70 //ndvi
71 var stacked_s2_ndvi = coll.clip(roi)
72
73 print('sentinel stack NDVI', stacked_s2_ndvi)
74
75
76
77 /***** FUNÇÃO PARA TRANSFORMAR CADA PONTO EM BUFFER
78 *****/
79 // Keep this list of properties.
```

```
80 var keepProperties = ['ID']
81
82 var buf = function (feat){
83   var buffer = ee.Feature(feat).buffer(raio)
84   return(buffer.copyProperties(feat, keepProperties));
85
86 var buffer = pontos.map(buf)
87
88 print(buffer)
89
90
91 // NDVI
92 var mean_ndvi = ee.Image(stacked_s2_ndvi).reduceRegions({
93   collection: buffer,
94   reducer: ee.Reducer.count()
95     .combine(ee.Reducer.mean(), null, true)
96     .combine(ee.Reducer.sampleStdDev(), null, true),
97   scale: 10});
98
99 print('media dos poligonos NDVI', mean_ndvi)
100
101
102 //CENTRALIZA NO MAPA
103 Map.centerObject(roi, 10);
104
105 // ADD COR AOS POLÍGONOS
106 Map.addLayer(roi, {color: 'red'}, 'Área de Interesse');
107
108 // ADD COR AOS POLÍGONOS
109 Map.addLayer(buffer, {color: 'black'}, 'Pontos de checagem');
110
111
112 // organização dos dados
113 var prefix = "ESTATISTICA-ZONAL-" + regiao + String("-") + String(data_inicial) +
```

```
114 String("-") + String(data_final);
115 // Export the data to a table for further analysis
116 //ndvi
117 Export.table.toDrive({
118   collection: mean_ndvi,
119   description: prefix+"_NDVI",
120   folder: 'GEE_PLANILHAS',
121   fileFormat:"CSV",
122 });
123
124
125 var grafico = ui.Chart.image.seriesByRegion({
126   imageCollection: ndvi,
127   regions: pontos,
128   reducer: ee.Reducer.mean(),
129   band: 'nd',
130   scale: 10,
131   xProperty: 'system:time_start',
132   seriesProperty: 'ID'
133 });
134
135 print(grafico)
136
```


Apêndice 2

Classification

Esse script é semelhante ao “Zonal Statistics” até a linha 64, porém para a classificação das áreas com nematoides foram usados pontos georreferenciados de treinamento (linha 6). A partir disso tem-se: criação de lista com a média de NDVI dentro de cada buffer (linhas 67 a 70); processo intermediário de listagem de nomes das bandas (linha 75); criação de lista com a média geral de NDVI para todos os buffers (linhas 77 a 83); criação de lista com o desvio padrão de NDVI para todos os buffers (linhas 88 a 93); binarização de cada imagem aproveitável (linhas 98 a 199); criação de coleção de imagens (linhas 202 e 203); criação imagem única, resultante da soma da coleção de imagens (linha 205); recorta a imagem para a área de interesse (linha 207); converte os dados para inteiros (linha 209); visualização dos dados (linhas 215 a 222); e por fim a exportação dos dados em formato de imagem GeoTIFF (226, 228, 230 a 236). A imagem foi então descarregada e usada no software QGIS para análise de acurácia com base nos pontos de verdade de campo.

```

1  /*****
2  *          PARÂMETROS FIXOS
3  *****/
4
5  // Informar o período em análise
6  var data_inicial = ('2019-01-01');
7
8  var data_final = ('2019-12-31');
9
10 var regioao = ('Prata-MG-NDVI') //ESPECIFICAR O MUNICÍPIO
11
12 //iNFORME O NOME DOS PONTOS
13 var pontos = table8
14
15 //DEfinir o raio do buffer em metros
16 var raio = 10

```

```
17
18 //Definir a porcentagem máxima de nuvem
19 var nuvem = 10
20
21 //informe o nome da área de interesse
22 var roi = table6
23
24
25 //Caso seja necessário descomente e insira o nome do TILE desejado
26 var MGRS_TILE = '22KGD';
27 var ON = 81;
28
29 // import data
30 //var modisNDVI = ee.ImageCollection("MODIS/006/MOD13Q1")
31 // .filterDate(data_inicial, data_final)
32 // .filterBounds(pontos)
33 // .select('NDVI')
34
35 //var clipcol = modisNDVI.clip(table2); // só corta um!!
36
37 var rename_band = function(img){
38   return img.select([0], [img.id()]);
39 };
40
41 // stack all the images into a single image.
42 //var stacked_image = modisNDVI.map(rename_band).toBands(); //iterate(combine, stacked_image);
43
44 //print(stacked_image)
45
46 /*
47 */
48 // Carrega Imagens Sentinel-2 TOA reflectance e corrige a atmosfera para BOA.
49 var collection = ee.ImageCollection('COPERNICUS/S2_SR')
50   .filterDate(data_inicial, data_final)
```

```

51 //filtro por região
52 .filterBounds(roi)
53 // Filtro de Nuvens
54 .filter(ee.Filter.lte('CLOUDY_PIXEL_PERCENTAGE', nuvem))
55 .filterMetadata('SENSING_ORBIT_NUMBER', 'equals', ON)
56 .filterMetadata('MGRS_TILE', 'contains', MGRS_TILE)
57 //limit(23)
58 //map(mask1);
59
60
61 // Function to calculate and add an NDVI band
62 var ndvi = function(image) {
63 return image.addBands(image.normalizedDifference(['B8', 'B4']));
64 };
65
66 //  $TGI = G - 0,39 * R - 0,61 * B$ 
67
68 // Function to calculate Vegetation Index
69 var iv = function (image){
70 // Expression for the NDVI
71 var tgi = image.expression(
72 '(green-0.39*red)*(red-0.61*blue)',
73 {
74 'blue':image.select('B2'),
75 'red':image.select('B4'),
76 'green': image.select('B3')
77 })
78 // Add the ndvi raster image in the Image Collection
79 image = image.addBands(tgi.rename('tgi'));
80
81 // Return each one raster image calculated
82 return image
83 }
84

```

```
85 // Add TGI band to image collection
86 var tgi = collection.map(iv);
87
88 print('sentinel tgi', tgi);
89
90 // Add NDVI band to image collection
91 var ndvi = collection.map(ndvi);
92
93 print('sentinel ndvi', ndvi);
94
95 // renomeia NDVI
96 var rename_band_ndvi = function(img){
97   return img.select(['nd'], [img.id()]);
98 };
99
100 // renomeia TGI
101 var rename_band_tgi = function(img){
102   return img.select(['tgi'], [img.id()]);
103 };
104
105 // renomeia tgi
106 var colltgi = tgi.map(rename_band_tgi).toBands()
107
108 //renomeia ndvi
109 var coll = ndvi.map(rename_band_ndvi).toBands()
110
111
112 print('sentinel ndvi', coll)
113 print('sentinel tgi', colltgi)
114
115 //tgi
116 var stacked_s2_tgi = colltgi.clip(roi)
117 //ndvi
118 var stacked_s2_ndvi = coll.clip(roi)
```

```
119
120 print('sentinel stack TGI', stacked_s2_tgi)
121 print('sentinel stack NDVI', stacked_s2_ndvi)
122
123 //TGI
124
125
126 /***** FUNÇÃO PARA TRANSFORMAR CADA PONTO EM BUFFER
127 *****/
128
129 var buf = function (feat){
130   return ee.Feature(feat).buffer(raio)}; // criar variavel para o tamanho do buffer
131
132 var buffer = pontos.map(buf)
133
134 print(buffer)
135
136 // determine scale to perform reduceRegions.
137 //var scale = stacked_s2.first().projection().nominalScale()
138
139 // NDVI
140 var mean_tgi = ee.Image(stacked_s2_tgi).reduceRegions({
141   collection: buffer,
142   reducer: ee.Reducer.mean(),
143   scale: 10});
144
145 // TGI
146 var mean_ndvi = ee.Image(stacked_s2_ndvi).reduceRegions({
147   collection: buffer,
148   reducer: ee.Reducer.mean(),
149   scale: 10});
150
151 print('media dos poligonos TGI', mean_tgi) //feature collection
152 print('media dos poligonos NDVI', mean_ndvi) //feature collection
```

```
153
154 var properties_tgi = stacked_s2_tgi.bandNames() //nome de cada coluna
155 var properties_ndvi = stacked_s2_ndvi.bandNames() //nome de cada coluna
156 //print(properties)
157
158 // media geral TGI
159 var statmean_tgi = mean_tgi.reduceColumns({
160   reducer: ee.Reducer.mean().repeat(34),
161   //inserir um contador automático de nº de imagens
162   selectors: properties_tgi,
163   //informa o nome de cada coluna
164   weightSelectors: null //adiciona um peso para o redutor
165 }).values().flatten()
166
167 // media geral NDVI
168 var statmean_ndvi = mean_ndvi.reduceColumns({
169   reducer: ee.Reducer.mean().repeat(34),
170   //inserir um contador automático de nº de imagens
171   selectors: properties_ndvi,
172   //informa o nome de cada coluna
173   weightSelectors: null //adiciona um peso para o redutor
174 }).values().flatten()
175
176
177 print('media geral TGI', statmean_tgi) //dicionário com a média dos buffers adicionados
178 print('media geral NDVI', statmean_ndvi) //dicionário com a média dos buffers adicionados
179
180 //criar o desvio...
181 // https://www.thoughtco.com/population-vs-sample-standard-deviations-3126372
182
183 //desvio TGI
184 var statstd_tgi = mean_tgi.reduceColumns({
185   reducer: ee.Reducer.sampleStdDev().repeat(34),
186   //inserir um contador automático de nº de imagens
```

```
187     selectors: properties_tgi,
188     weightSelectors: null
189   }).values().flatten()
190
191   var statstd_ndvi = mean_ndvi.reduceColumns({
192     reducer: ee.Reducer.sampleStdDev().repeat(34),
193     //inserir um contador automático de nº de imagens
194     selectors: properties_ndvi,
195     weightSelectors: null
196   }).values().flatten()
197
198   print('desvio padrão', statstd_tgi)
199   print('desvio padrão', statstd_ndvi)//dicionário com o desvio dos buffers adicionados
200
201   // criar função para calcular o limite inferior e superior... inf = media - desvio // sup = media + desvio
202
203   // tgi
204   var inf_tgi = ee.List([statmean_tgi.getNumber(0).subtract(statstd_tgi.getNumber(0))]
205     .add([statmean_tgi.getNumber(1).subtract(statstd_tgi.getNumber(1))]
206     .add([statmean_tgi.getNumber(2).subtract(statstd_tgi.getNumber(2))]
207     .add([statmean_tgi.getNumber(3).subtract(statstd_tgi.getNumber(3))]
208     .add([statmean_tgi.getNumber(4).subtract(statstd_tgi.getNumber(4))]
209     .add([statmean_tgi.getNumber(5).subtract(statstd_tgi.getNumber(5))]
210     .add([statmean_tgi.getNumber(6).subtract(statstd_tgi.getNumber(6))]
211     .add([statmean_tgi.getNumber(7).subtract(statstd_tgi.getNumber(7))]
212     .add([statmean_tgi.getNumber(8).subtract(statstd_tgi.getNumber(8))]
213     .add([statmean_tgi.getNumber(9).subtract(statstd_tgi.getNumber(9))]
214     .add([statmean_tgi.getNumber(10).subtract(statstd_tgi.getNumber(10))]
215     .add([statmean_tgi.getNumber(11).subtract(statstd_tgi.getNumber(11))]
216     .add([statmean_tgi.getNumber(12).subtract(statstd_tgi.getNumber(12))]
217     .add([statmean_tgi.getNumber(13).subtract(statstd_tgi.getNumber(13))]
218     .add([statmean_tgi.getNumber(14).subtract(statstd_tgi.getNumber(14))]
219     .add([statmean_tgi.getNumber(15).subtract(statstd_tgi.getNumber(15))]
220     .add([statmean_tgi.getNumber(16).subtract(statstd_tgi.getNumber(16))])
```

```
221 .add([statmean_tgi.getNumber(17).subtract(statstd_tgi.getNumber(17))])
222 .add([statmean_tgi.getNumber(18).subtract(statstd_tgi.getNumber(18))])
223 .add([statmean_tgi.getNumber(19).subtract(statstd_tgi.getNumber(19))])
224 .add([statmean_tgi.getNumber(20).subtract(statstd_tgi.getNumber(20))])
225 .add([statmean_tgi.getNumber(21).subtract(statstd_tgi.getNumber(21))])
226 .add([statmean_tgi.getNumber(22).subtract(statstd_tgi.getNumber(22))])
227 .add([statmean_tgi.getNumber(23).subtract(statstd_tgi.getNumber(23))])
228 .add([statmean_tgi.getNumber(24).subtract(statstd_tgi.getNumber(24))])
229 .add([statmean_tgi.getNumber(25).subtract(statstd_tgi.getNumber(25))])
230 .add([statmean_tgi.getNumber(26).subtract(statstd_tgi.getNumber(26))])
231 .add([statmean_tgi.getNumber(27).subtract(statstd_tgi.getNumber(27))])
232 .add([statmean_tgi.getNumber(28).subtract(statstd_tgi.getNumber(28))])
233 .add([statmean_tgi.getNumber(29).subtract(statstd_tgi.getNumber(29))])
234 .add([statmean_tgi.getNumber(30).subtract(statstd_tgi.getNumber(30))])
235 .add([statmean_tgi.getNumber(31).subtract(statstd_tgi.getNumber(31))])
236 .add([statmean_tgi.getNumber(32).subtract(statstd_tgi.getNumber(32))])
237 .add([statmean_tgi.getNumber(33).subtract(statstd_tgi.getNumber(33))])
238 .flatten()
239
240 print('limite inferior TGI', inf_tgi)
241
242 var sup_tgi = ee.List([statmean_tgi.getNumber(0).add(statstd_tgi.getNumber(0))])
243 .add([statmean_tgi.getNumber(1).add(statstd_tgi.getNumber(1))])
244 .add([statmean_tgi.getNumber(2).add(statstd_tgi.getNumber(2))])
245 .add([statmean_tgi.getNumber(3).add(statstd_tgi.getNumber(3))])
246 .add([statmean_tgi.getNumber(4).add(statstd_tgi.getNumber(4))])
247 .add([statmean_tgi.getNumber(5).add(statstd_tgi.getNumber(5))])
248 .add([statmean_tgi.getNumber(6).add(statstd_tgi.getNumber(6))])
249 .add([statmean_tgi.getNumber(7).add(statstd_tgi.getNumber(7))])
250 .add([statmean_tgi.getNumber(8).add(statstd_tgi.getNumber(8))])
251 .add([statmean_tgi.getNumber(9).add(statstd_tgi.getNumber(9))])
252 .add([statmean_tgi.getNumber(10).add(statstd_tgi.getNumber(10))])
253 .add([statmean_tgi.getNumber(11).add(statstd_tgi.getNumber(11))])
254 .add([statmean_tgi.getNumber(12).add(statstd_tgi.getNumber(12))])
```



```

255 .add([statmean_tgi.getNumber(13).add(statstd_tgi.getNumber(13))])
256 .add([statmean_tgi.getNumber(14).add(statstd_tgi.getNumber(14))])
257 .add([statmean_tgi.getNumber(15).add(statstd_tgi.getNumber(15))])
258 .add([statmean_tgi.getNumber(16).add(statstd_tgi.getNumber(16))])
259 .add([statmean_tgi.getNumber(17).add(statstd_tgi.getNumber(17))])
260 .add([statmean_tgi.getNumber(18).add(statstd_tgi.getNumber(18))])
261 .add([statmean_tgi.getNumber(19).add(statstd_tgi.getNumber(19))])
262 .add([statmean_tgi.getNumber(20).add(statstd_tgi.getNumber(20))])
263 .add([statmean_tgi.getNumber(21).add(statstd_tgi.getNumber(21))])
264 .add([statmean_tgi.getNumber(22).add(statstd_tgi.getNumber(22))])
265 .add([statmean_tgi.getNumber(23).add(statstd_tgi.getNumber(23))])
266 .add([statmean_tgi.getNumber(24).add(statstd_tgi.getNumber(24))])
267 .add([statmean_tgi.getNumber(25).add(statstd_tgi.getNumber(25))])
268 .add([statmean_tgi.getNumber(26).add(statstd_tgi.getNumber(26))])
269 .add([statmean_tgi.getNumber(27).add(statstd_tgi.getNumber(27))])
270 .add([statmean_tgi.getNumber(28).add(statstd_tgi.getNumber(28))])
271 .add([statmean_tgi.getNumber(29).add(statstd_tgi.getNumber(29))])
272 .add([statmean_tgi.getNumber(30).add(statstd_tgi.getNumber(30))])
273 .add([statmean_tgi.getNumber(31).add(statstd_tgi.getNumber(31))])
274 .add([statmean_tgi.getNumber(32).add(statstd_tgi.getNumber(32))])
275 .add([statmean_tgi.getNumber(33).add(statstd_tgi.getNumber(33))])
276 .flatten()
277
278 print('limite superior TGI', sup_tgi)
279
280 // ndvi
281
282 var inf_ndvi = ee.List([statmean_ndvi.getNumber(0).subtract(statstd_ndvi.getNumber(0))])
283 .add([statmean_ndvi.getNumber(1).subtract(statstd_ndvi.getNumber(1))])
284 .add([statmean_ndvi.getNumber(2).subtract(statstd_ndvi.getNumber(2))])
285 .add([statmean_ndvi.getNumber(3).subtract(statstd_ndvi.getNumber(3))])
286 .add([statmean_ndvi.getNumber(4).subtract(statstd_ndvi.getNumber(4))])
287 .add([statmean_ndvi.getNumber(5).subtract(statstd_ndvi.getNumber(5))])
288 .add([statmean_ndvi.getNumber(6).subtract(statstd_ndvi.getNumber(6))])

```

```

289 .add([statmean_ndvi.getNumber(7).subtract(statstd_ndvi.getNumber(7))])
290 .add([statmean_ndvi.getNumber(8).subtract(statstd_ndvi.getNumber(8))])
291 .add([statmean_ndvi.getNumber(9).subtract(statstd_ndvi.getNumber(9))])
292 .add([statmean_ndvi.getNumber(10).subtract(statstd_ndvi.getNumber(10))])
293 .add([statmean_ndvi.getNumber(11).subtract(statstd_ndvi.getNumber(11))])
294 .add([statmean_ndvi.getNumber(12).subtract(statstd_ndvi.getNumber(12))])
295 .add([statmean_ndvi.getNumber(13).subtract(statstd_ndvi.getNumber(13))])
296 .add([statmean_ndvi.getNumber(14).subtract(statstd_ndvi.getNumber(14))])
297 .add([statmean_ndvi.getNumber(15).subtract(statstd_ndvi.getNumber(15))])
298 .add([statmean_ndvi.getNumber(16).subtract(statstd_ndvi.getNumber(16))])
299 .add([statmean_ndvi.getNumber(17).subtract(statstd_ndvi.getNumber(17))])
300 .add([statmean_ndvi.getNumber(18).subtract(statstd_ndvi.getNumber(18))])
301 .add([statmean_ndvi.getNumber(19).subtract(statstd_ndvi.getNumber(19))])
302 .add([statmean_ndvi.getNumber(20).subtract(statstd_ndvi.getNumber(20))])
303 .add([statmean_ndvi.getNumber(21).subtract(statstd_ndvi.getNumber(21))])
304 .add([statmean_ndvi.getNumber(22).subtract(statstd_ndvi.getNumber(22))])
305 .add([statmean_ndvi.getNumber(23).subtract(statstd_ndvi.getNumber(23))])
306 .add([statmean_ndvi.getNumber(24).subtract(statstd_ndvi.getNumber(24))])
307 .add([statmean_ndvi.getNumber(25).subtract(statstd_ndvi.getNumber(25))])
308 .add([statmean_ndvi.getNumber(26).subtract(statstd_ndvi.getNumber(26))])
309 .add([statmean_ndvi.getNumber(27).subtract(statstd_ndvi.getNumber(27))])
310 .add([statmean_ndvi.getNumber(28).subtract(statstd_ndvi.getNumber(28))])
311 .add([statmean_ndvi.getNumber(29).subtract(statstd_ndvi.getNumber(29))])
312 .add([statmean_ndvi.getNumber(30).subtract(statstd_ndvi.getNumber(30))])
313 .add([statmean_ndvi.getNumber(31).subtract(statstd_ndvi.getNumber(31))])
314 .add([statmean_ndvi.getNumber(32).subtract(statstd_ndvi.getNumber(32))])
315 .add([statmean_ndvi.getNumber(33).subtract(statstd_ndvi.getNumber(33))])
316 .flatten()
317
318 print('limite inferior ndvi', inf_ndvi)
319
320 var sup_ndvi = ee.List([statmean_ndvi.getNumber(0).add(statstd_ndvi.getNumber(0))])
321 .add([statmean_ndvi.getNumber(1).add(statstd_ndvi.getNumber(1))])
322 .add([statmean_ndvi.getNumber(2).add(statstd_ndvi.getNumber(2))])

```

```
323 .add([statmean_ndvi.getNumber(3).add(statstd_ndvi.getNumber(3))])
324 .add([statmean_ndvi.getNumber(4).add(statstd_ndvi.getNumber(4))])
325 .add([statmean_ndvi.getNumber(5).add(statstd_ndvi.getNumber(5))])
326 .add([statmean_ndvi.getNumber(6).add(statstd_ndvi.getNumber(6))])
327 .add([statmean_ndvi.getNumber(7).add(statstd_ndvi.getNumber(7))])
328 .add([statmean_ndvi.getNumber(8).add(statstd_ndvi.getNumber(8))])
329 .add([statmean_ndvi.getNumber(9).add(statstd_ndvi.getNumber(9))])
330 .add([statmean_ndvi.getNumber(10).add(statstd_ndvi.getNumber(10))])
331 .add([statmean_ndvi.getNumber(11).add(statstd_ndvi.getNumber(11))])
332 .add([statmean_ndvi.getNumber(12).add(statstd_ndvi.getNumber(12))])
333 .add([statmean_ndvi.getNumber(13).add(statstd_ndvi.getNumber(13))])
334 .add([statmean_ndvi.getNumber(14).add(statstd_ndvi.getNumber(14))])
335 .add([statmean_ndvi.getNumber(15).add(statstd_ndvi.getNumber(15))])
336 .add([statmean_ndvi.getNumber(16).add(statstd_ndvi.getNumber(16))])
337 .add([statmean_ndvi.getNumber(17).add(statstd_ndvi.getNumber(17))])
338 .add([statmean_ndvi.getNumber(18).add(statstd_ndvi.getNumber(18))])
339 .add([statmean_ndvi.getNumber(19).add(statstd_ndvi.getNumber(19))])
340 .add([statmean_ndvi.getNumber(20).add(statstd_ndvi.getNumber(20))])
341 .add([statmean_ndvi.getNumber(21).add(statstd_ndvi.getNumber(21))])
342 .add([statmean_ndvi.getNumber(22).add(statstd_ndvi.getNumber(22))])
343 .add([statmean_ndvi.getNumber(23).add(statstd_ndvi.getNumber(23))])
344 .add([statmean_ndvi.getNumber(24).add(statstd_ndvi.getNumber(24))])
345 .add([statmean_ndvi.getNumber(25).add(statstd_ndvi.getNumber(25))])
346 .add([statmean_ndvi.getNumber(26).add(statstd_ndvi.getNumber(26))])
347 .add([statmean_ndvi.getNumber(27).add(statstd_ndvi.getNumber(27))])
348 .add([statmean_ndvi.getNumber(28).add(statstd_ndvi.getNumber(28))])
349 .add([statmean_ndvi.getNumber(29).add(statstd_ndvi.getNumber(29))])
350 .add([statmean_ndvi.getNumber(30).add(statstd_ndvi.getNumber(30))])
351 .add([statmean_ndvi.getNumber(31).add(statstd_ndvi.getNumber(31))])
352 .add([statmean_ndvi.getNumber(32).add(statstd_ndvi.getNumber(32))])
353 .add([statmean_ndvi.getNumber(33).add(statstd_ndvi.getNumber(33))])
354 .flatten()
355
356 print('limite superior ndvi', sup_ndvi)
```

```
357
358
359
360 // tgi
361 var img1 = stacked_s2_tgi.select([0])
362 .gte(statmean_tgi.getNumber(0).subtract(statstd_tgi.getNumber(0)))
363 .and(stacked_s2_tgi.select([0])
364 .lte(statmean_tgi.getNumber(0).add(statstd_tgi.getNumber(0))))).rename('TGI')
365
366 var img2 = stacked_s2_tgi.select([1])
367 .gte(statmean_tgi.getNumber(1).subtract(statstd_tgi.getNumber(1)))
368 .and(stacked_s2_tgi.select([1])
369 .lte(statmean_tgi.getNumber(1).add(statstd_tgi.getNumber(1))))).rename('TGI')
370
371 var img3 = stacked_s2_tgi.select([2])
372 .gte(statmean_tgi.getNumber(2).subtract(statstd_tgi.getNumber(2)))
373 .and(stacked_s2_tgi.select([2])
374 .lte(statmean_tgi.getNumber(2).add(statstd_tgi.getNumber(2))))).rename('TGI')
375
376 var img4 = stacked_s2_tgi.select([3])
377 .gte(statmean_tgi.getNumber(3).subtract(statstd_tgi.getNumber(3)))
378 .and(stacked_s2_tgi.select([3])
379 .lte(statmean_tgi.getNumber(3).add(statstd_tgi.getNumber(3))))).rename('TGI')
380
381 var img5 = stacked_s2_tgi.select([4])
382 .gte(statmean_tgi.getNumber(4).subtract(statstd_tgi.getNumber(4)))
383 .and(stacked_s2_tgi.select([4])
384 .lte(statmean_tgi.getNumber(4).add(statstd_tgi.getNumber(4))))).rename('TGI')
385
386 var img6 = stacked_s2_tgi.select([5])
387 .gte(statmean_tgi.getNumber(5).subtract(statstd_tgi.getNumber(5)))
388 .and(stacked_s2_tgi.select([5])
389 .lte(statmean_tgi.getNumber(5).add(statstd_tgi.getNumber(5))))).rename('TGI')
390
```

```
391 var img7 = stacked_s2_tgi.select([6])
392 .gte(statmean_tgi.getNumber(6).subtract(statstd_tgi.getNumber(6)))
393 .and(stacked_s2_tgi.select([6])
394 .lte(statmean_tgi.getNumber(6).add(statstd_tgi.getNumber(6))))).rename('TGI')
395
396 var img8 = stacked_s2_tgi.select([7])
397 .gte(statmean_tgi.getNumber(7).subtract(statstd_tgi.getNumber(7)))
398 .and(stacked_s2_tgi.select([7])
399 .lte(statmean_tgi.getNumber(7).add(statstd_tgi.getNumber(7))))).rename('TGI')
400
401 var img9 = stacked_s2_tgi.select([8])
402 .gte(statmean_tgi.getNumber(8).subtract(statstd_tgi.getNumber(8)))
403 .and(stacked_s2_tgi.select([8])
404 .lte(statmean_tgi.getNumber(8).add(statstd_tgi.getNumber(8))))).rename('TGI')
405
406 var img10 = stacked_s2_tgi.select([9])
407 .gte(statmean_tgi.getNumber(9).subtract(statstd_tgi.getNumber(9)))
408 .and(stacked_s2_tgi.select([9])
409 .lte(statmean_tgi.getNumber(9).add(statstd_tgi.getNumber(9))))).rename('TGI')
410
411 var img11 = stacked_s2_tgi.select([10])
412 .gte(statmean_tgi.getNumber(10).subtract(statstd_tgi.getNumber(10)))
413 .and(stacked_s2_tgi.select([10])
414 .lte(statmean_tgi.getNumber(10).add(statstd_tgi.getNumber(10))))).rename('TGI')
415
416 var img12 = stacked_s2_tgi.select([11])
417 .gte(statmean_tgi.getNumber(11).subtract(statstd_tgi.getNumber(11)))
418 .and(stacked_s2_tgi.select([11])
419 .lte(statmean_tgi.getNumber(11).add(statstd_tgi.getNumber(11))))).rename('TGI')
420
421 var img13 = stacked_s2_tgi.select([12])
422 .gte(statmean_tgi.getNumber(12).subtract(statstd_tgi.getNumber(12)))
423 .and(stacked_s2_tgi.select([12])
424 .lte(statmean_tgi.getNumber(12).add(statstd_tgi.getNumber(12))))).rename('TGI')
```

```
425
426 var img14 = stacked_s2_tgi.select([13])
427 .gte(statmean_tgi.getNumber(13).subtract(statstd_tgi.getNumber(13)))
428 .and(stacked_s2_tgi.select([13])
429 .lte(statmean_tgi.getNumber(13).add(statstd_tgi.getNumber(13))))).rename('TGI')
430
431 var img15 = stacked_s2_tgi.select([14])
432 .gte(statmean_tgi.getNumber(14).subtract(statstd_tgi.getNumber(14)))
433 .and(stacked_s2_tgi.select([14])
434 .lte(statmean_tgi.getNumber(14).add(statstd_tgi.getNumber(14))))).rename('TGI')
435
436 var img16 = stacked_s2_tgi.select([15])
437 .gte(statmean_tgi.getNumber(15).subtract(statstd_tgi.getNumber(15)))
438 .and(stacked_s2_tgi.select([15])
439 .lte(statmean_tgi.getNumber(15).add(statstd_tgi.getNumber(15))))).rename('TGI')
440
441 var img17 = stacked_s2_tgi.select([16])
442 .gte(statmean_tgi.getNumber(16).subtract(statstd_tgi.getNumber(16)))
443 .and(stacked_s2_tgi.select([16])
444 .lte(statmean_tgi.getNumber(16).add(statstd_tgi.getNumber(16))))).rename('TGI')
445
446 var img18 = stacked_s2_tgi.select([17])
447 .gte(statmean_tgi.getNumber(17).subtract(statstd_tgi.getNumber(17)))
448 .and(stacked_s2_tgi.select([17])
449 .lte(statmean_tgi.getNumber(17).add(statstd_tgi.getNumber(17))))).rename('TGI')
450
451 var img19 = stacked_s2_tgi.select([18])
452 .gte(statmean_tgi.getNumber(18).subtract(statstd_tgi.getNumber(18)))
453 .and(stacked_s2_tgi.select([18])
454 .lte(statmean_tgi.getNumber(18).add(statstd_tgi.getNumber(18))))).rename('TGI')
455
456 var img20 = stacked_s2_tgi.select([19])
457 .gte(statmean_tgi.getNumber(19).subtract(statstd_tgi.getNumber(19)))
458 .and(stacked_s2_tgi.select([19])
```

```
459 .lte(statmean_tgi.getNumber(19).add(statstd_tgi.getNumber(19))).rename('TGI')
460
461 var img21 = stacked_s2_tgi.select([20])
462 .gte(statmean_tgi.getNumber(20).subtract(statstd_tgi.getNumber(20)))
463 .and(stacked_s2_tgi.select([20])
464 .lte(statmean_tgi.getNumber(20).add(statstd_tgi.getNumber(20))).rename('TGI')
465
466 var img22 = stacked_s2_tgi.select([21])
467 .gte(statmean_tgi.getNumber(21).subtract(statstd_tgi.getNumber(21)))
468 .and(stacked_s2_tgi.select([21])
469 .lte(statmean_tgi.getNumber(21).add(statstd_tgi.getNumber(21))).rename('TGI')
470
471 var img23 = stacked_s2_tgi.select([22])
472 .gte(statmean_tgi.getNumber(22).subtract(statstd_tgi.getNumber(22)))
473 .and(stacked_s2_tgi.select([22])
474 .lte(statmean_tgi.getNumber(22).add(statstd_tgi.getNumber(22))).rename('TGI')
475
476 var img24 = stacked_s2_tgi.select([23])
477 .gte(statmean_tgi.getNumber(23).subtract(statstd_tgi.getNumber(23)))
478 .and(stacked_s2_tgi.select([23])
479 .lte(statmean_tgi.getNumber(23).add(statstd_tgi.getNumber(23))).rename('TGI')
480
481 var img25 = stacked_s2_tgi.select([24])
482 .gte(statmean_tgi.getNumber(24).subtract(statstd_tgi.getNumber(24)))
483 .and(stacked_s2_tgi.select([24])
484 .lte(statmean_tgi.getNumber(24).add(statstd_tgi.getNumber(24))).rename('TGI')
485
486 var img26 = stacked_s2_tgi.select([25])
487 .gte(statmean_tgi.getNumber(25).subtract(statstd_tgi.getNumber(25)))
488 .and(stacked_s2_tgi.select([25])
489 .lte(statmean_tgi.getNumber(25).add(statstd_tgi.getNumber(25))).rename('TGI')
490
491 var img27 = stacked_s2_tgi.select([26])
492 .gte(statmean_tgi.getNumber(26).subtract(statstd_tgi.getNumber(26)))
```

```
493 .and(stacked_s2_tgi.select([26])
494 .lte(statmean_tgi.getNumber(26).add(statstd_tgi.getNumber(26)))).rename('TGI')
495
496 var img28 = stacked_s2_tgi.select([27])
497 .gte(statmean_tgi.getNumber(27).subtract(statstd_tgi.getNumber(27)))
498 .and(stacked_s2_tgi.select([27])
499 .lte(statmean_tgi.getNumber(27).add(statstd_tgi.getNumber(27)))).rename('TGI')
500
501 var img29 = stacked_s2_tgi.select([28])
502 .gte(statmean_tgi.getNumber(28).subtract(statstd_tgi.getNumber(28)))
503 .and(stacked_s2_tgi.select([28])
504 .lte(statmean_tgi.getNumber(28).add(statstd_tgi.getNumber(28)))).rename('TGI')
505
506 var img30 = stacked_s2_tgi.select([29])
507 .gte(statmean_tgi.getNumber(29).subtract(statstd_tgi.getNumber(29)))
508 .and(stacked_s2_tgi.select([29])
509 .lte(statmean_tgi.getNumber(29).add(statstd_tgi.getNumber(29)))).rename('TGI')
510
511 var img31 = stacked_s2_tgi.select([30])
512 .gte(statmean_tgi.getNumber(30).subtract(statstd_tgi.getNumber(30)))
513 .and(stacked_s2_tgi.select([30])
514 .lte(statmean_tgi.getNumber(30).add(statstd_tgi.getNumber(30)))).rename('TGI')
515
516 var img32 = stacked_s2_tgi.select([31])
517 .gte(statmean_tgi.getNumber(31).subtract(statstd_tgi.getNumber(22)))
518 .and(stacked_s2_tgi.select([31])
519 .lte(statmean_tgi.getNumber(31).add(statstd_tgi.getNumber(31)))).rename('TGI')
520
521 var img33 = stacked_s2_tgi.select([32])
522 .gte(statmean_tgi.getNumber(32).subtract(statstd_tgi.getNumber(32)))
523 .and(stacked_s2_tgi.select([32])
524 .lte(statmean_tgi.getNumber(32).add(statstd_tgi.getNumber(32)))).rename('TGI');
525
526 var img34 = stacked_s2_tgi.select([33])
```



```
527 .gte(statmean_tgi.getNumber(33).subtract(statstd_tgi.getNumber(33)))
528 .and(stacked_s2_tgi.select([33])
529 .lte(statmean_tgi.getNumber(33).add(statstd_tgi.getNumber(33))))).rename('TGI');
530
531
532 var test_tgi = ee.ImageCollection([img1, img2, img3, img4, img5, img6, img7, img8,
533 img9, img10, img11, img12, img13, img14, img15, img16, img17, img18,
534 img19, img20, img21, img22, img23, img24, img25, img26, img27, img28, img29,
535 img30, img31, img32, img33]);
536
537 var test_tgi = test_tgi.sum();//reduce(ee.Reducer.sum());
538
539 var qt = test_tgi.clip(roi);
540
541 var tq = ee.Image(qt).toInt();
542
543 // ndvi
544 var img_1 = stacked_s2_ndvi.select([0])
545 .gte(statmean_ndvi.getNumber(0).subtract(statstd_ndvi.getNumber(0)))
546 .and(stacked_s2_ndvi.select([0])
547 .lte(statmean_ndvi.getNumber(0).add(statstd_ndvi.getNumber(0))))).rename('NDVI')
548
549 var img_2 = stacked_s2_ndvi.select([1])
550 .gte(statmean_ndvi.getNumber(1).subtract(statstd_ndvi.getNumber(1)))
551 .and(stacked_s2_ndvi.select([1])
552 .lte(statmean_ndvi.getNumber(1).add(statstd_ndvi.getNumber(1))))).rename('NDVI')
553
554 var img_3 = stacked_s2_ndvi.select([2])
555 .gte(statmean_ndvi.getNumber(2).subtract(statstd_ndvi.getNumber(2)))
556 .and(stacked_s2_ndvi.select([2])
557 .lte(statmean_ndvi.getNumber(2).add(statstd_ndvi.getNumber(2))))).rename('NDVI')
558
559 var img_4 = stacked_s2_ndvi.select([3])
560 .gte(statmean_ndvi.getNumber(3).subtract(statstd_ndvi.getNumber(3)))
```

```
561 .and(stacked_s2_ndvi.select([3])
562 .lte(statmean_ndvi.getNumber(3).add(statstd_ndvi.getNumber(3))))).rename('NDVI')
563
564 var img_5 = stacked_s2_ndvi.select([4])
565 .gte(statmean_ndvi.getNumber(4).subtract(statstd_ndvi.getNumber(4)))
566 .and(stacked_s2_ndvi.select([4])
567 .lte(statmean_ndvi.getNumber(4).add(statstd_ndvi.getNumber(4))))).rename('NDVI')
568
569 var img_6 = stacked_s2_ndvi.select([5])
570 .gte(statmean_ndvi.getNumber(5).subtract(statstd_ndvi.getNumber(5)))
571 .and(stacked_s2_ndvi.select([5])
572 .lte(statmean_ndvi.getNumber(5).add(statstd_ndvi.getNumber(5))))).rename('NDVI')
573
574 var img_7 = stacked_s2_ndvi.select([6])
575 .gte(statmean_ndvi.getNumber(6).subtract(statstd_ndvi.getNumber(6)))
576 .and(stacked_s2_ndvi.select([6])
577 .lte(statmean_ndvi.getNumber(6).add(statstd_ndvi.getNumber(6))))).rename('NDVI')
578
579 var img_8 = stacked_s2_ndvi.select([7])
580 .gte(statmean_ndvi.getNumber(7).subtract(statstd_ndvi.getNumber(7)))
581 .and(stacked_s2_ndvi.select([7])
582 .lte(statmean_ndvi.getNumber(7).add(statstd_ndvi.getNumber(7))))).rename('NDVI')
583
584 var img_9 = stacked_s2_ndvi.select([8])
585 .gte(statmean_ndvi.getNumber(8).subtract(statstd_ndvi.getNumber(8)))
586 .and(stacked_s2_ndvi.select([8])
587 .lte(statmean_ndvi.getNumber(8).add(statstd_ndvi.getNumber(8))))).rename('NDVI')
588
589 var img_10 = stacked_s2_ndvi.select([9])
590 .gte(statmean_ndvi.getNumber(9).subtract(statstd_ndvi.getNumber(9)))
591 .and(stacked_s2_ndvi.select([9])
592 .lte(statmean_ndvi.getNumber(9).add(statstd_ndvi.getNumber(9))))).rename('NDVI')
593
594 var img_11 = stacked_s2_ndvi.select([10])
```

```
595 .gte(statmean_ndvi.getNumber(10).subtract(statstd_ndvi.getNumber(10)))
596 .and(stacked_s2_ndvi.select([10])
597 .lte(statmean_ndvi.getNumber(10).add(statstd_ndvi.getNumber(10))))).rename('NDVI');
598
599 var img_12 = stacked_s2_ndvi.select([11])
600 .gte(statmean_ndvi.getNumber(11).subtract(statstd_ndvi.getNumber(11)))
601 .and(stacked_s2_ndvi.select([11])
602 .lte(statmean_ndvi.getNumber(11).add(statstd_ndvi.getNumber(11))))).rename('NDVI');
603
604 var img_13 = stacked_s2_ndvi.select([12])
605 .gte(statmean_ndvi.getNumber(12).subtract(statstd_ndvi.getNumber(12)))
606 .and(stacked_s2_ndvi.select([12])
607 .lte(statmean_ndvi.getNumber(12).add(statstd_ndvi.getNumber(12))))).rename('NDVI');
608
609 var img_14 = stacked_s2_ndvi.select([13])
610 .gte(statmean_ndvi.getNumber(13).subtract(statstd_ndvi.getNumber(13)))
611 .and(stacked_s2_ndvi.select([13])
612 .lte(statmean_ndvi.getNumber(13).add(statstd_ndvi.getNumber(13))))).rename('NDVI');
613
614 var img_15 = stacked_s2_ndvi.select([14])
615 .gte(statmean_ndvi.getNumber(14).subtract(statstd_ndvi.getNumber(14)))
616 .and(stacked_s2_ndvi.select([14])
617 .lte(statmean_ndvi.getNumber(14).add(statstd_ndvi.getNumber(14))))).rename('NDVI');
618
619 var img_16 = stacked_s2_ndvi.select([15])
620 .gte(statmean_ndvi.getNumber(15).subtract(statstd_ndvi.getNumber(15)))
621 .and(stacked_s2_ndvi.select([15])
622 .lte(statmean_ndvi.getNumber(15).add(statstd_ndvi.getNumber(15))))).rename('NDVI');
623
624 var img_17 = stacked_s2_ndvi.select([16])
625 .gte(statmean_ndvi.getNumber(16).subtract(statstd_ndvi.getNumber(16)))
626 .and(stacked_s2_ndvi.select([16])
627 .lte(statmean_ndvi.getNumber(16).add(statstd_ndvi.getNumber(16))))).rename('NDVI');
628
```

```
629 var img_18 = stacked_s2_ndvi.select([17])
630 .gte(statmean_ndvi.getNumber(17).subtract(statstd_ndvi.getNumber(17)))
631 .and(stacked_s2_ndvi.select([17])
632 .lte(statmean_ndvi.getNumber(17).add(statstd_ndvi.getNumber(17))))).rename('NDVI');
633
634 var img_19 = stacked_s2_ndvi.select([18])
635 .gte(statmean_ndvi.getNumber(18).subtract(statstd_ndvi.getNumber(18)))
636 .and(stacked_s2_ndvi.select([18])
637 .lte(statmean_ndvi.getNumber(18).add(statstd_ndvi.getNumber(18))))).rename('NDVI');
638
639 var img_20 = stacked_s2_ndvi.select([19])
640 .gte(statmean_ndvi.getNumber(19).subtract(statstd_ndvi.getNumber(19)))
641 .and(stacked_s2_ndvi.select([19])
642 .lte(statmean_ndvi.getNumber(19).add(statstd_ndvi.getNumber(19))))).rename('NDVI');
643
644 var img_21 = stacked_s2_ndvi.select([20])
645 .gte(statmean_ndvi.getNumber(20).subtract(statstd_ndvi.getNumber(20)))
646 .and(stacked_s2_ndvi.select([20])
647 .lte(statmean_ndvi.getNumber(20).add(statstd_ndvi.getNumber(20))))).rename('NDVI');
648
649 var img_22 = stacked_s2_ndvi.select([21])
650 .gte(statmean_ndvi.getNumber(21).subtract(statstd_ndvi.getNumber(21)))
651 .and(stacked_s2_ndvi.select([21])
652 .lte(statmean_ndvi.getNumber(21).add(statstd_ndvi.getNumber(21))))).rename('NDVI')
653
654 var img_23 = stacked_s2_ndvi.select([22])
655 .gte(statmean_ndvi.getNumber(22).subtract(statstd_ndvi.getNumber(22)))
656 .and(stacked_s2_ndvi.select([22])
657 .lte(statmean_ndvi.getNumber(22).add(statstd_ndvi.getNumber(22))))).rename('NDVI')
658
659 var img_24 = stacked_s2_ndvi.select([23])
660 .gte(statmean_ndvi.getNumber(23).subtract(statstd_ndvi.getNumber(23)))
661 .and(stacked_s2_ndvi.select([23])
662 .lte(statmean_ndvi.getNumber(23).add(statstd_ndvi.getNumber(23))))).rename('NDVI')
```

```
663
664 var img_25 = stacked_s2_ndvi.select([24])
665 .gte(statmean_ndvi.getNumber(24).subtract(statstd_ndvi.getNumber(24)))
666 .and(stacked_s2_ndvi.select([24])
667 .lte(statmean_ndvi.getNumber(24).add(statstd_ndvi.getNumber(24))))).rename('NDVI')
668
669 var img_26 = stacked_s2_ndvi.select([25])
670 .gte(statmean_ndvi.getNumber(25).subtract(statstd_ndvi.getNumber(25)))
671 .and(stacked_s2_ndvi.select([25])
672 .lte(statmean_ndvi.getNumber(25).add(statstd_ndvi.getNumber(25))))).rename('NDVI')
673
674 var img_27 = stacked_s2_ndvi.select([26])
675 .gte(statmean_ndvi.getNumber(26).subtract(statstd_ndvi.getNumber(26)))
676 .and(stacked_s2_ndvi.select([26])
677 .lte(statmean_ndvi.getNumber(26).add(statstd_ndvi.getNumber(26))))).rename('NDVI')
678
679 var img_28 = stacked_s2_ndvi.select([27])
680 .gte(statmean_ndvi.getNumber(27).subtract(statstd_ndvi.getNumber(27)))
681 .and(stacked_s2_ndvi.select([27])
682 .lte(statmean_ndvi.getNumber(27).add(statstd_ndvi.getNumber(27))))).rename('NDVI')
683
684 var img_29 = stacked_s2_ndvi.select([28])
685 .gte(statmean_ndvi.getNumber(28).subtract(statstd_ndvi.getNumber(28)))
686 .and(stacked_s2_ndvi.select([28])
687 .lte(statmean_ndvi.getNumber(28).add(statstd_ndvi.getNumber(28))))).rename('NDVI')
688
689 var img_30 = stacked_s2_ndvi.select([29])
690 .gte(statmean_ndvi.getNumber(29).subtract(statstd_ndvi.getNumber(29)))
691 .and(stacked_s2_ndvi.select([29])
692 .lte(statmean_ndvi.getNumber(29).add(statstd_ndvi.getNumber(29))))).rename('NDVI')
693
694 var img_31 = stacked_s2_ndvi.select([30])
695 .gte(statmean_ndvi.getNumber(30).subtract(statstd_ndvi.getNumber(30)))
696 .and(stacked_s2_ndvi.select([30])
```

```

697 .lte(statmean_ndvi.getNumber(30).add(statstd_ndvi.getNumber(30))).rename('NDVI')
698
699 var img_32 = stacked_s2_ndvi.select([31])
700 .gte(statmean_ndvi.getNumber(31).subtract(statstd_ndvi.getNumber(22)))
701 .and(stacked_s2_ndvi.select([31])
702 .lte(statmean_ndvi.getNumber(31).add(statstd_ndvi.getNumber(31)))).rename('NDVI')
703
704 var img_33 = stacked_s2_ndvi.select([32])
705 .gte(statmean_ndvi.getNumber(32).subtract(statstd_ndvi.getNumber(32)))
706 .and(stacked_s2_ndvi.select([32])
707 .lte(statmean_ndvi.getNumber(32).add(statstd_ndvi.getNumber(32)))).rename('NDVI')
708
709 var img_34 = stacked_s2_ndvi.select([33])
710 .gte(statmean_ndvi.getNumber(33).subtract(statstd_ndvi.getNumber(33)))
711 .and(stacked_s2_ndvi.select([33])
712 .lte(statmean_ndvi.getNumber(33).add(statstd_ndvi.getNumber(33)))).rename('NDVI')
713
714
715 var test_ndvi = ee.ImageCollection([img_1, img_2, img_3, img_4, img_5, img_6, img_7, img_8,
716 img_9, img_10, img_11, img_12, img_13, img_14, img_15, img_16, img_17, img_18,
717 img_19, img_20, img_21, img_22, img_23, img_24, img_25, img_26, img_27, img_28, img_29,
718 img_30, img_31, img_32, img_33]);
719
720 var test_ndvi = test_ndvi.sum()//reduce(ee.Reducer.sum());
721
722 var qt = test_ndvi.clip(roi)
723
724 var tq_ndvi = ee.Image(qt).toInt()
725
726 //print image
727 print('Map of coincidence TGI', tq);
728 print('Map of coincidence NDVI', tq_ndvi);
729
730 // PALETA DE CORES - ROI

```

```
731 var COLOR = {
732   VERMELHO: 'ff0000',
733   AZUL: '0000ff',
734   VERDE: '00ff00'
735 };
736
737 // PALETA DE CORES - MODIS
738 var palette = ['#FFFFFF','#CE7E45','#DF923D','#F1B555','#FCD163','#99B718','#74A901',
739   '#66A000','#529400','#3E8601','#207401','#056201','#004C00','#023B01','#012E01',
740   '#011D01','#011301'];
741
742
743 // ADD COMPOSIÇÃO MODIS - NDVI
744 Map.addLayer(test_tgi, {min:0, max:34, bands:['TGI'], palette: palette}, 'coincidencia TGI')
745 Map.addLayer(test_ndvi, {min:0, max:34, bands:['NDVI'], palette: palette}, 'coincidencia NDVI')
746
747
748 //CENTRALIZA NO MAPA
749 Map.centerObject(roi, 10);
750
751 // ADD COR AOS POLÍGONOS
752 Map.addLayer(roi, {color: COLOR.VERMELHO}, 'Área de Interesse');
753
754 // ADD COR AOS POLÍGONOS
755 Map.addLayer(buffer, {color: COLOR.VERMELHO}, 'Amostras');
756
757 //// ADD COR AOS POLÍGONOS
758 //Map.addLayer(buffer, {color: COLOR.VERMELHO}, 'buffer');
759
760
761 //Export.image.toDrive({
762 // image: stacked_image,
763 // description: regiao,
764 // region: table2,
```

```
765 // scale: 250,
766 // crs: 'EPSG:4326',
767 // maxPixels: 1e13})
768
769 // organização dos dados
770 var prefix = "ESTATISTICA-ZONAL-" + regiao + String("-") + String(data_inicial) + String("-") + String(data_final);
771
772 // Export the data to a table for further analysis
773 Export.table.toDrive({
774   collection: mean_tgi,
775   description: prefix+"TGI",
776   folder: 'GEE_PLANILHAS',
777   fileFormat:"CSV",
778   //selectors:["nome_coluna1","nome_coluna2"]
779 });
780
781 //ndvi
782 Export.table.toDrive({
783   collection: mean_ndvi,
784   description: prefix,
785   folder: 'GEE_PLANILHAS',
786   fileFormat:"CSV",
787   //selectors:["nome_coluna1","nome_coluna2"]
788 });
789
790 //tgi
791 Export.image.toDrive({
792   image: tq,
793   description: regiao+"-TGI",
794   region: roi.geometry().bounds().transform('EPSG:32723', 100),
795   scale: 10,
796   crs: 'EPSG:32723',
797   maxPixels: 1e13});
798
```



```
799 //ndvi
800 Export.image.toDrive({
801   image: tq_ndvi,
802   description: regioao,
803   region: roi.geometry().bounds().transform('EPSG:32723', 100),
804   scale: 10,
805   crs: 'EPSG:32723',
806   maxPixels: 1e13});
807
808
809 var areaexp = ee.FeatureCollection(roi)
810   .filterMetadata('id_prop', 'starts_with', 1);
811
812
813 var grafico = ui.Chart.image.seriesByRegion({
814   imageCollection: ndvi,
815   regions: pontos,
816   reducer: ee.Reducer.mean(),
817   band: 'nd',
818   scale: 10 })
819
820 print(grafico
```

Apêndice 3

Distribuição populacional de nematoídeos por amostra georreferenciada no município de Prata, MG, em cm^{-3} solo e em g^{-1} raiz.

N°	Coordenada		Nematoídeos																								
			Meloidogyne		Pratylenchus		Aphelenchoïdes		Cricememella		Rotylenchus		Aphelenchus		Helicotylenchus												
			Solo	Raiz	Total	Solo	Raiz	Total	Solo	Raiz	Total	Solo	Raiz	Total	Solo	Raiz	Total										
1	19.374019	48.892251	4	0	4	0	12	12	12	8	20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
2	19.379900	48.875206	12	68	80	0	44	44	8	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	19.313407	48.896768	10	20	30	4	50	54	4	6	10	4	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0
4	19.307152	48.882022	0	0	0	0	38	38	12	6	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	19.280380	48.879920	0	4	4	0	48	48	0	4	4	0	4	4	0	0	0	0	0	0	0	0	0	0	0	0	0
6	19.280410	48.882930	4	24	28	0	12	12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	8
7	19.250320	48.822930	8	26	34	0	35	35	2	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	19.240053	48.818250	0	0	0	6	23	29	8	8	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	19.211640	48.938860	0	0	0	0	108	108	20	12	32	0	0	0	4	0	4	0	0	0	0	0	0	0	0	0	0
10	19.208630	48.939940	0	0	0	8	56	64	10	4	14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
11	19.205050	48.941130	0	0	0	0	27	27	4	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
12	19.125034	48.955621	0	0	0	12	40	52	4	4	8	8	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0
13	19.129390	48.958460	8	0	8	0	80	80	8	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
14	19.129980	48.950990	6	8	14	22	56	78	10	0	10	4	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0
15	19.112190	48.936640	2	4	6	9	25	34	0	5	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
16	19.107400	48.937380	0	0	0	0	30	30	8	6	14	2	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0
17	19.156040	49.008600	38	65	103	30	243	273	0	4	4	16	0	16	0	0	0	0	0	0	0	0	0	0	0	0	0
18	19.159530	49.012310	24	172	196	39	152	191	0	6	6	22	0	22	0	0	0	0	0	0	0	0	0	0	0	0	0
19	19.180650	48.942600	0	0	0	0	72	72	12	6	18	0	0	0	0	0	0	0	0	0	0	0	6	0	6	0	0
20	19.176885	48.943636	0	0	0	6	28	34	4	4	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
21	19.324610	48.942550	0	0	0	18	54	72	2	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
22	19.361280	48.980980	0	4	4	4	12	16	0	0	0	4	0	4	4	0	4	0	4	0	0	0	0	0	0	0	0
23	19.346080	48.996570	0	0	0	20	1352	1372	0	8	8	40	0	40	0	0	0	0	0	0	0	0	0	0	0	0	0
24	19.336510	49.003920	4	188	192	4	1548	1552	0	8	8	8	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0
25	19.358920	49.015320	0	0	0	12	204	216	6	4	10	8	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0

Continua...

ANEXOS**Anexo 1**

Valores de interpretação para o coeficiente de concordância de Kappa (LANDIS; KOCH, 1977).

Valor de Kappa	Interpretação
< 0	Insignificante
0 - 0,2	Fraca
0,21 - 0,4	Razoável
0,41 - 0,6	Moderada
0,61 - 0,8	Forte
0,81 - 1	Quase perfeita