



**UNESP – UNIVERSIDADE ESTADUAL PAULISTA  
“JÚLIO DE MESQUITA FILHO”**

Faculdade de Ciências e Tecnologia - Presidente Prudente  
Programa de Pós-Graduação em Ciências Cartográficas

**FRANCIELE MARQUES TOLENTINO**

**CONTRIBUIÇÃO DE SÉRIES TEMPORAIS DE ATRIBUTOS  
ÓPTICOS E SAR NA DISCRIMINAÇÃO DO CAFEEIRO INFESTADO  
POR NEMATOIDES**



Presidente Prudente, 2023



**UNESP – UNIVERSIDADE ESTADUAL PAULISTA  
“JÚLIO DE MESQUITA FILHO”**

Faculdade de Ciências e Tecnologia - Presidente Prudente  
Programa de Pós-Graduação em Ciências Cartográficas

**FRANCIELE MARQUES TOLENTINO**

**CONTRIBUIÇÃO DE SÉRIES TEMPORAIS DE ATRIBUTOS  
ÓPTICOS E SAR NA DISCRIMINAÇÃO DO CAFEIEIRO INFESTADO  
POR NEMATOIDES**



Tese de Doutorado ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista campus de Presidente Prudente.

Orientador: Prof. Dra. Maria de Lourdes B. T. Galo

Coorientador: Prof. Dr. George Deroco Martins

---

T649c Tolentino, Franciele Marques  
Contribuição de séries temporais de atributos ópticos e SAR na  
discriminação do cafeeiro infestado por nematoides. / Franciele  
Marques Tolentino. -- Presidente Prudente, 2023  
149 f.

Tese (doutorado) - Universidade Estadual Paulista (Unesp),  
Faculdade de Ciências e Tecnologia, Presidente Prudente  
Orientadora: Maria de Lourdes Bueno Trindade Galo  
Coorientador: George Deroco Martins

1. SAR. 2. Sentinel. 3. Séries Temporais. 4. Nematoides. 5. Redes  
Neurais Recorrentes.. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de  
Ciências e Tecnologia, Presidente Prudente. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Presidente Prudente

**CERTIFICADO DE APROVAÇÃO**

**TÍTULO DA TESE:** Contribuição de séries temporais de atributos ópticos e SAR na discriminação do cafeeiro infestado por nematoides

**AUTORA:** FRANCIELE MARQUES TOLENTINO

**ORIENTADORA:** MARIA DE LOURDES BUENO TRINDADE GALO

**COORIENTADOR:** GEORGE DEROCO MARTINS

Aprovada como parte das exigências para obtenção do Título de Doutora em Ciências Cartográficas, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:

Profa. Dra. MARIA DE LOURDES BUENO TRINDADE GALO (Participação Presencial)  
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente - FCT/Unesp

Profa. Dra. FERNANDA SAYURI YOSHINO WATANABE (Participação Presencial)  
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente - FCT/Unesp

Profa. Dra. ANA PAULA MARQUES RAMOS (Participação Presencial)  
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente - FCT/Unesp

Prof. Dr. BRUNO SÉRGIO VIEIRA (Participação Virtual)  
Instituto de Ciências Agrárias / Universidade Federal de Uberlândia - UFU

Prof. Dr. ULISSES SILVA GUIMARÃES (Participação Presencial)  
Divisão de Sensoriamento Remoto / Centro Gestor e Operacional do Sistema de Proteção da Amazônia - Censipam

Presidente Prudente, 30 de novembro de 2023

---

## **IMPACTO ESPERADO DESTA PESQUISA<sup>1</sup>**

Esta tese apresenta um estudo desenvolvido para discriminar áreas infestadas por nematoides na cultura cafeeira a partir de séries temporais de dados de sensoriamento remoto. Os nematoides são patógenos que parasitam o sistema radicular da planta, de modo que a infecção é detectada quando ocorrem mudanças estruturais na parte aérea do cafeeiro. Alterações no comportamento sazonal da planta podem ser monitoradas a partir de séries temporais de atributos extraídos de imagens ópticas e SAR, uma vez que dados ópticos detectam variações na composição bioquímica da vegetação, enquanto os dados SAR são sensíveis a estrutura e fenologia da planta, podendo ser adquiridos em condições climáticas adversas. As séries temporais fornecem informações importantes sobre a cultura ao longo do seu ciclo de desenvolvimento, permitindo o monitoramento sistemático da lavoura, um componente essencial no controle da disseminação de nematoides para outras áreas de cultivo. Por fim, destaca-se que a metodologia desenvolvida nesta pesquisa pode ser estendida para outras culturas e doenças/patógenos, consolidando o uso de séries temporais de atributos SAR no monitoramento de culturas agrícolas.

## **POTENTIAL IMPACT OF THIS RESEARCH**

This thesis presents a study developed to discriminate root-knot nematodes (RKN) in coffee crops, based on time series of optical and SAR remote sensing data. Nematodes are pathogens that parasitize the plant's root system, so the infection is detected when structural changes occur in the aerial part of the coffee tree. Changes in the plant's seasonal behaviour can be monitored from time series of the optical and SAR features, as optical data detects variations in the biochemical composition of vegetation, while SAR data is sensitive to plant structure and phenology and can be acquired in adverse weather conditions. Time series provide valuable information about the crop throughout its development cycle, allowing the systematic crop monitoring, an essential component in controlling the spread RKN to other cultivation areas. Finally, we expect that the methodology developed in this research can be extended to other crops and diseases/pathogens, consolidating the use of time series of SAR features in crop monitoring.

<sup>1</sup>Informação inserida de acordo com a Portaria Unesp no 117, de 21 de dezembro de 2022

---

## AGRADECIMENTOS

Aos meus pais e meus irmãos, agradeço por sempre estarem ao meu lado e compreenderem a minha ausência enquanto eu me dedicava à pós-graduação. Ao Guilherme, pelo companheirismo, compreensão, apoio e por sempre estar ao meu lado quando eu mais precisei.

Aos meus orientadores Profa. Dra. Maria de Lourdes Bueno Trindade Galo e Prof. Dr. George Deroco Martins, pela paciência, conhecimento compartilhado, confiança e por todo o tempo dedicado. À minha supervisora durante o estágio na *Purdue University*, Dr. Crawford e ao seu grupo de pesquisa em Sensoriamento Remoto (*Laboratory for Applications of Remote Sensing*).

Aos amigos que o PPGCC e a Unesp me proporcionaram: Ge, Vivi, Isa, Renatinho, Gui Cardim, Ana Lúcia e Gabi. Ao Prof. Erivaldo e sua esposa Marisa pelas conversas e, principalmente, pela amizade. Aos amigos e colegas do DNIT, obrigada pelo apoio nessa reta final do doutorado.

Ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC), à Universidade Estadual Paulista (UNESP) pela infraestrutura fornecida.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e do Programa Institucional de Internacionalização (Capes-PrInt - Processo 88887.570058/2020-00).

---

## RESUMO

O café é uma importante *commodity* agrícola, sendo o Brasil o maior produtor mundial. No entanto, a produção do cafeeiro pode ser afetada por patógenos, especialmente nematoides, que prejudicam a absorção de água e nutrientes pelas raízes, levando à redução da produção e até a morte das plantas. Como os métodos tradicionais de detecção de nematoides são caros e se restringem a coleta de amostras em campo, o sensoriamento remoto tem sido considerado uma ferramenta apropriada para o monitoramento da cultura cafeeira. Além de melhorias nas resoluções espaciais, espectrais e temporais, os satélites do programa Sentinel possuem sensores que operam no espectro óptico e micro-ondas, o que aumentou as oportunidades para monitoramento agrícola. Nesse contexto, o objetivo desse trabalho é desenvolver um estudo para discriminação de áreas infestadas por nematoides na cultura cafeeira, por meio de séries temporais de atributos ópticos e SAR em diferentes fases fenológicas do cafeeiro. Para isso, foram consideradas duas abordagens: a primeira busca discriminar áreas infestadas por nematoides, bem como identificar a fase fenológica ideal para essa discriminação a partir da análise de séries temporais de atributos derivados de imagens ópticas e SAR. A segunda utiliza combinações de séries temporais de atributos ópticos e SAR via redes BiLSTM para discriminar áreas infestadas por nematoides. Na primeira abordagem foram analisados perfis temporais dos atributos derivados das imagens Sentinel-1 e Sentinel-2, além da análise de separabilidade entre talhões sadios e infestados e identificação dos atributos de maior importância. Na segunda abordagem, as séries temporais de atributos ópticos e SAR foram aplicadas a uma rede BiLSTM e, por fim, foram geradas classificações em uma área teste. Os resultados da primeira abordagem mostraram que os atributos ópticos na região do *red-edge* e SWIR e a polarização  $\sigma^0VV$  são capazes de discriminar áreas infestadas por nematoides. Além disso, a análise de importância de atributos indica as fases de maturação dos frutos (abril – junho) e autopoda (julho – agosto) como as mais apropriadas para detecção do patógeno. Os resultados da segunda abordagem alcançaram menores valores de *recall* para séries temporais muito curtas, como 12 e 24 meses. Ao considerar fases fenológicas específicas, a fase de maturação dos frutos foi a que apresentou os melhores resultados, tanto para os atributos ópticos e SAR, quanto para a combinação deles. A aplicação do método proposto na classificação da área teste revelou que quando utilizado somente atributos SAR, são detectadas áreas menores e mais fragmentadas nas séries temporais mais longas, sugerindo a necessidade de sequência de dados maiores para essa detecção. Além disso, a classificação a partir de atributos SAR mantiveram o padrão de detecção para séries temporais maiores que 24 meses. Em contrapartida, os experimentos com séries temporais de dados ópticos mostraram maior variação no padrão de detecção, especialmente quando dados de 2020 e 2021 foram adicionados. Isso indica que as séries temporais de atributos SAR têm potencial para detecção de nematoides na cultura cafeeira. Por fim, os resultados alcançados neste trabalho se mostraram promissores, demonstrando o potencial da utilização de séries temporais de dados Sentinel para discriminação de áreas cafeeiras infestadas por nematoides.

**Palavras-chave:** SAR, Sentinel, Séries Temporais, Cafeicultura, Nematoides, Redes Neurais Recorrentes.

---

## ABSTRACT

Coffee is one of the most important agricultural commodities in foreign trade and Brazil is the largest producer and exporter of coffee in the world. However, coffee production can be reduced by pathogens, especially root-knot nematodes (RKN), which cause damage at the root level and, consequently, affect the absorption of water and nutrients. Since the traditional methods for detecting nematodes are expensive and restrict a few samples on the field. Given the high cost and limited field sample collection associated with traditional nematode detection methods, remote sensing has been considered an appropriate tool for efficient monitoring of crop health. The launches of Sentinel (optical and SAR) platforms by the European Space Agency (ESA) have increased opportunities for agricultural monitoring, leading to improvements in spatial, spectral, and temporal resolutions. The objective of this thesis is to develop a study to discriminate areas infested by nematodes in coffee crops, through the time series of Sentinel 2 optical and Sentinel-1 SAR features in different phenological phases. To achieve this, two approaches were considered: The first approach aims to discriminate fields infested by RKN and identify the key phenological stage through the analysis of time series optical and SAR features. In the second approach, the BiLSTM model was applied to time series of optical, and SAR features, aiming to discriminate fields infested by RKN. Finally, classifications were generated for a test area. The results of the first approach showed that optical features in the red-edge and SWIR region, as well as  $\sigma^0$  VV polarization can discriminate fields infested by RKN. Furthermore, feature importance analysis indicates that fruit maturation and fallow stages are the most suitable stages for RKN detection. The second approach achieved lower recall values for short time series, such as 12 and 24 months. When considering specific phenological stages, the fruit maturation stage exhibited the best results, both for optical and SAR features, as well as their combination. The nematodes detection in the test area revealed that experiments with SAR data were more consistent, and smaller, and more fragmented areas were detected in the longer time series, suggesting the need for a larger data sequence for this detection. In addition, the detection of nematodes in the test area revealed that experiments with SAR data were more consistent, maintaining a detection pattern for time series longer than 24 months. In contrast, experiments with time series of optical data exhibited greater variation in the detection pattern, especially when data from 2020 and 2021 were added. These results indicate that time series of SAR features have great potential in RKN detection. Finally, the results achieved in this thesis were promising, demonstrating the potential of using Sentinel data time series to discriminate areas infested by RKN.

**Keywords:** SAR, Sentinel, time series, coffee crop, root-knot nematodes, recurrent neural network.

---

## LISTA DE FIGURAS

|  |    |
|--|----|
| <b>Figura 1</b> – Esquematização das fases fenológicas do cafeeiro para o período de 24 meses. ....  | 9  |
| <b>Figura 2</b> – Esquematização das fases fenológicas do cafeeiro para o período de 12 meses. ..  | 10 |
| <b>Figura 3</b> - Série histórica da produção (toneladas) de café no Cerrado Mineiro de 1990 a 2021.<br>.....  | 12 |
| <b>Figura 4</b> - Espectros de reflectância dos alvos. ....  | 13 |
| <b>Figura 5</b> - Espectros de refletância da vegetação sadia e senescente. ....   | 14 |
| <b>Figura 6</b> - Princípio de imageamento do radar. ....  | 15 |
| <b>Figura 7</b> - Componentes de um sistema radar. ....  | 17 |
| <b>Figura 8</b> - Geometria de um sistema SAR.....   | 18 |
| <b>Figura 9</b> - Polarizações dos sinais radar: (a) polarização horizontal, (b) polarização vertical, (c) co-polarização vertical (VV) e (d) polarização cruzada (VH). ....   | 19 |
| <b>Figura 10</b> - Padrão do retroespalhamento a partir da superfície imageada: (a) lisa, (b) levemente rugosa e (c) rugosa.....   | 19 |
| <b>Figura 11</b> - Distorções geométricas em sistemas radares: (a) foreshortening em faixa inclinada, (b) layover em faixa inclinada e (c) shadow em faixa inclinada. ....   | 20 |
| <b>Figura 12</b> - Interação do sinal retroespalhado com a vegetação quando ocorre: (a) espalhamento superficial atenuado pelo dossel da vegetação, (b) espalhamento múltiplo e (c) retroespalhamento atenuado pelo solo.....                              | 22 |
| <b>Figura 13</b> - Resposta teórica da vegetação à energia de micro-ondas das bandas L, C e X....  | 22 |
| <b>Figura 14</b> - Série temporal de imagens ordenadas no tempo destacando um pixel (x, y). ....   | 25 |
| <b>Figura 15</b> - Modelo de rede neural com duas camadas escondidas.....  | 27 |
| <b>Figura 16</b> - Representação de uma rede neural: (a) feedforward e (b) rede neural recorrente.<br>.....  | 29 |
| <b>Figura 17</b> - Estrutura de uma RNR ao longo do tempo.....   | 29 |
| <b>Figura 18</b> - Estrutura de uma rede LSTM. ....  | 30 |
| <b>Figura 19</b> - Área de estudo e distribuição de talhões de café. Polígonos em amarelo representam a localização de talhões de café. No destaque: polígonos em verde representam talhões saudios e os polígonos em vermelho os talhões infestados. .... | 32 |

---

|   |    |
|---|----|
| <b>Figura 20</b> - Representação gráfica de variáveis climatológicas registradas mensalmente, no município de Monte Carmelo entre os anos de 2017 e 2021. As barras representam a precipitação acumulada no mês (mm) e as linhas pontilhadas representam a temperatura média mensal (°C).....   | 33 |
| <b>Figura 21</b> - Área em que o cafezal foi removido entre os anos de 2018 e 2020 .....  | 34 |
| <b>Figura 22</b> - Delineamento amostral usado na definição das áreas de referência para geração dos perfis temporais. Polígonos em vermelho, inseridos nos talhões I1, I2 e I3 indicam áreas infestadas, enquanto os polígonos em verde dos talhões S1, S2 e S3 são talhões com cafeeiros sadios. ....   | 34 |
| <b>Figura 23</b> - Exemplos de cafeeiros infestados por nematoides no município de Monte Carmelo – MG.....  | 35 |
| <b>Figura 24</b> - Fluxograma geral das etapas de pré-processamento dos dados Sentinel-1 e Sentinel-2. ....   | 38 |
| <b>Figura 25</b> - Representação das datas das imagens Sentinel-1 e Sentinel-2. Em vermelho é representado as datas das imagens ópticas Sentinel-1 e em azul as datas das imagens Sentinel-2. ....  | 39 |
| <b>Figura 26</b> - Ilustração das calibrações sigma nought ( $\sigma^0$ ), beta nought ( $\beta^0$ ) e gamma ( $\gamma^0$ )..   | 40 |
| <b>Figura 27</b> - (a) Reflectância média para as bandas espectrais do Sentinel-2 e valores normalizados dos atributos Sentinel-1 de talhões sadios e infestados por nematoides. Na Figura (a) a largura da faixa refere-se ao desvio padrão dos valores de reflectância para cada banda. ....  | 43 |
| <b>Figura 28</b> - Métodos propostos para análise da discriminação entre talhões sadios e infestados a partir de atributos extraídos de séries temporais.....   | 46 |
| <b>Figura 29</b> - Representação esquemática das séries temporais de atributos ópticos e SAR. As linhas em verde ilustram áreas cafeeiras sadias e as linhas em vermelho ilustram áreas infestadas por nematoides. Além disso, os retângulos em amarelo, laranja, marrom e verde representam as fases de formação dos grãos, maturação dos frutos, autopoda e vegetativa, respectivamente. As letras representam as iniciais dos meses que compõem cada fase fenológica. .... | 48 |
| <b>Figura 30</b> - Perfis temporais, entre os anos de 2019 e 2020, dos valores médios mensais dos atributos NDVI (a) e coeficientes de retroespalhamento das polarizações $\sigma^0_{VV}$ e $\sigma^0_{VH}$ (b) durante as principais fases fenológicas do cafeeiro.....  | 51 |
| <b>Figura 31</b> – Perfis temporais dos valores médios dos atributos: (a) B4 (vermelho), (b) B5 ( <i>red-edge</i> 1), (c) B6 ( <i>red-edge</i> 2), (d) B7 ( <i>red-edge</i> 3), (e) B8 (NIR), (f) B8A ( <i>red-edge</i> 4), (g) B11 (SWIR 1), (h) B12 (SWIR 2), e (i) NDVI. As linhas verdes e vermelhas representam os talhões sadios e infestados, respectivamente (continua).....  | 53 |

---

|   |    |
|---|----|
| <b>Figura 32</b> – Perfis temporais dos atributos polarimétricos SAR (a) $\sigma^0VV$ [dB], (b) $\sigma^0VH$ [dB], (c) $\text{sumVVVH}$ [dB] (d) $\text{subVVVH}$ [dB], (e) $\text{ratioVVVH}$ [dB], e (f) RVI. As linhas verdes e vermelhas representam os talhões sadios e infestados, respectivamente. ....  | 55 |
| <b>Figura 33</b> - Diferença nos valores médios dos atributos ópticos de talhões sadios e infestados por nematoides. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa.....  | 58 |
| <b>Figura 34</b> - Diferença nos valores de variância dos atributos ópticos de talhões sadios e infestados por nematoides. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. ....   | 60 |
| <b>Figura 35</b> - Diferença nos valores de média dos atributos SAR de talhões sadios e infestados por nematoides. Devido os atributos possuírem diferentes intervalos de valores, eles são apresentados em: (a) discrepâncias para os atributos $\sigma^0VV$ , $\sigma^0VH$ , $\text{sumVVVH}$ , $\text{subVVVH}$ e (b) discrepâncias para os atributos $\text{ratioVVVH}$ e RVI. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. .... | 61 |
| <b>Figura 36</b> - Diferença nos valores de variância dos atributos SAR de talhões sadios e infestados por nematoides. Devido os atributos possuírem diferentes intervalos de valores, eles são apresentados em: (a) discrepâncias para os atributos $VV$ , $VH$ , $\text{sumVVVH}$ , $\text{subVVVH}$ e (b) discrepâncias para os atributos $\text{ratioVVVH}$ e RVI. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. ....             | 63 |
| <b>Figura 37</b> - Importância dos atributos ópticos em discriminar entre talhões sadios e infestados por fase fenológica: (a) formação dos grãos, (b) maturação dos frutos, (c) autopoda, e (d) vegetativo. As letras m e v se referem a média e a variância, respectivamente. ....  | 65 |
| <b>Figura 38</b> - Importância dos atributos SAR em discriminar entre talhões sadios e infestados por fase fenológica: (a) formação dos grãos, (b) maturação dos frutos, (c) autopoda, e (d) vegetativo. As letras m e v se referem a média e v a variância.....  | 66 |
| <b>Figura 39</b> - Fluxograma utilizado para aplicação de redes BiLSTM para detecção de nematoides.....   | 69 |
| <b>Figura 40</b> - Representação de uma rede BiLSTM. ....   | 70 |
| <b>Figura 41</b> - Arquitetura de rede BiLSTM utilizada. ....   | 71 |
| <b>Figura 42</b> - Definição dos cenários experimentais. ....   | 75 |
| <b>Figura 43</b> - Área utilizada para aplicação da rede BiLSTM.....  | 76 |
| <b>Figura 44</b> -Valores obtidos para as métricas <i>recall</i> em função do tamanho da série temporal. As barras verdes e laranjas representam as classe sadio e infestado, respectivamente. ....   | 77 |
| <b>Figura 45</b> - Valores obtidos para a métrica <i>recall</i> ao combinar atributos ópticos e SAR, em função do tamanho da série temporal. ....   | 78 |

---

|   |    |
|---|----|
| <b>Figura 46</b> - Valores obtidos para a métrica <i>recall</i> para as diferentes fases fenológicas. As barras verdes e laranjas representam as classe sadio e infestado, respectivamente. ....  | 79 |
| <b>Figura 47</b> - Valores obtidos para a métrica <i>recall</i> para as diferentes fases fenológicas.....   | 80 |
| <b>Figura 48</b> – Distribuição espacial de áreas infestadas por nematoides a partir de dados ópticos: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho. ....                              | 82 |
| <b>Figura 49</b> -Detecção de área infestada por nematoides a partir de atributos SAR: (a) $\sigma_0VV$ , (b) $\sigma_0VH$ e (c) sumVVVH. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho. ....  | 85 |
| <b>Figura 50</b> - Detecção de área infestada por nematoides a partir da combinação de dados ópticos e a polarização $\sigma_0VV$ : (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho. .... | 87 |
| <b>Figura 51</b> – Distribuição espacial de áreas infestadas por nematoides a partir de dados ópticos: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho. ....                              | 89 |
| <b>Figura 52</b> – Distribuição espacial de áreas infestadas por nematoides a partir de dados ópticos: (a) $\sigma_0VV$ , (b) $\sigma_0VH$ e (c) sumVVVH. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.....   | 92 |
| <b>Figura 53</b> – Detecção de área infestada por nematoides a partir da combinação de dados ópticos e polarização $\sigma_0VV$ : (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho. ....   | 94 |

---

## LISTA DE TABELAS

|  |    |
|--|----|
| <b>Tabela 1</b> - Trabalhos relacionados ao uso de aprendizagem de máquina para detecção de patógenos em culturas agrícolas utilizando dados de sensoriamento remoto. ....   | 4  |
| <b>Tabela 2</b> - Trabalhos que utilizam dados SAR para detecção de pestes e doenças em culturas agrícolas.....  | 5  |
| <b>Tabela 3</b> - Área destinada a colheita e quantidade produzida nos anos de 2020 e 2021 no Brasil, Minas Gerais e nos dez maiores produtores de café do Cerrado Mineiro.....  | 12 |
| <b>Tabela 4</b> - Comprimento de onda e frequência das bandas SAR. ....  | 16 |
| <b>Tabela 5</b> - Resposta teórica das medições ópticas e de SAR às mudanças nas condições da vegetação/ solo, onde ↑ indica aumento e ↓ indica diminuição.....  | 21 |
| <b>Tabela 6</b> – Dimensão e número de pixels de cada área de referência sadia (S1, S2 e S3) e infestada (I1, I2 e I3). A informação de Área (ha) refere-se ao tamanho do talhão de referência preliminarmente a subamostragem dos polígonos para remoção de solo exposto. ....  | 35 |
| <b>Tabela 7</b> - Configuração espectral e resolução espacial de imagens Sentinel-2.....   | 36 |
| <b>Tabela 8</b> – Especificação de cada parâmetro das imagens Sentinel-1.....  | 36 |
| <b>Tabela 9</b> - Resumo dos atributos obtidos para dados Sentinel-1 e Sentinel-2. $\rho$ é a reflectância de superfície em uma banda espectral específica e $\sigma_0$ é o coeficiente de retroespalhamento na polarização VV ou VH. NDVI é o Índice de Vegetação por Diferença Normalizada. ....   | 42 |
| <b>Tabela 10</b> - P-valor obtido a partir do teste MWW indicando a significância das diferenças dos atributos ópticos (média). FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao p-valor $\leq 0,05$ .....        | 58 |
| <b>Tabela 11</b> - P-valor obtido a partir do teste de Lavene indicando significância dos valores de variância dos atributos ópticos. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao p-valor $\leq 0,05$ . .... | 60 |
| <b>Tabela 12</b> - P-valor obtido a partir do teste MWW indicando a significância das diferenças dos atributos SAR (média). FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao p-valor $\leq 0,05$ . ....           | 61 |
| <b>Tabela 13</b> - P-valor obtido a partir do teste Lavene indicando a significância das diferenças dos atributos SAR (variância). FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao p-valor $\leq 0,05$ . ....    | 63 |

---

|  |    |
|--|----|
| <b>Tabela 14</b> - Hiperparâmetros utilizados na rede BiLSTM.....  | 72 |
| <b>Tabela 15</b> - Combinação de atributos utilizados no treinamento da rede BiLSTM. ....  | 73 |
| <b>Tabela 16</b> - F-Score para a combinação de atributos ópticos. S representa a classe sadio e I representa a classe infestado. O gradiente de cores indica os valores da métrica F-Score em ordem decrescente .....               | 81 |
| <b>Tabela 17</b> - F-Score para os atributos SAR. S representa a classe sadio e I representa a classe infestado. O gradiente de cores indica os valores da métrica F-Score em ordem decrescente.                                     | 84 |
| <b>Tabela 18</b> - F-Score para a combinação de ópticos e a polarização $\sigma 0VV$ .....   | 85 |
| <b>Tabela 19</b> - F-Score para a combinação de ópticos e a polarização $\sigma 0VH$ .....   | 85 |
| <b>Tabela 20</b> - F-Score para a combinação de ópticos e o atributo $\text{sum}VVVH$ .....  | 86 |
| <b>Tabela 21</b> - F-Score para a combinação de atributos ópticos. S representa a classe sadio e I representa a classe infestado. O gradiente de cores indica os valores da métrica F-Score em ordem decrescente. ....               | 88 |
| <b>Tabela 22</b> – Valores de F-Score obtidos para a combinação de atributos SAR. S representa a classe sadio e I representa a classe infestado. O gradiente de cores indica os valores da métrica F-Score em ordem decrescente..... | 91 |
| <b>Tabela 23</b> - F-Score para as combinações de atributos ópticos e a polarização $\sigma 0VV$ .....   | 93 |
| <b>Tabela 24</b> - F-Score para as combinações de atributos ópticos e a polarização $\sigma 0VH$ .....   | 93 |
| <b>Tabela 25</b> - F-Score para as combinações de atributos ópticos e o atributo $\text{sum}VVVH$ .....  | 93 |

---

## LISTA DE QUADROS

|   |    |
|---|----|
| <b>Quadro 1</b> - Comparação entre dados ópticos e SAR no estudo da vegetação.....  | 21 |
| <b>Quadro 2</b> - Datas das imagens Sentinel-1 e Sentinel-2 que compuseram o conjunto de dados. Os retângulos em amarelo representam ausência imagem no mês considerado. .... | 39 |

---

## LISTA DE ABREVIATURAS E SÍMBOLOS

|           |   |
|-----------|---|
| AP        | Autopoda  |
| B3        | Banda da região do verde no espectro eletromagnético        |
| B4        | Banda da região do vermelho no espectro eletromagnético     |
| B5        | Banda da região do red-edge 1 no espectro eletromagnético   |
| B6        | Banda da região do red-edge 2 no espectro eletromagnético   |
| B7        | Banda da região do red-edge 3 no espectro eletromagnético   |
| B8        | Banda da região do NIR no espectro eletromagnético          |
| B8A       | Banda da região do red-edge 4 no espectro eletromagnético   |
| B11       | Banda da região do SWIR 1 no espectro eletromagnético       |
| B12       | Banda da região do SWIR 2 no espectro eletromagnético       |
| BiLSTM    | <i>Bi-directional Long Short-Term Memory</i>                |
| dB        | unidades de decibéis  |
| ESA       | <i>European Space Agency</i>                                |
| EW        | <i>Extra Wide swath</i>                                     |
| FG        | Formação dos Grãos  |
| GDAL      | <i>Geospatial Data Abstraction Library</i>                  |
| GRD       | <i>Ground Range Detected</i>                                |
| GRU       | <i>Gated Recurrent Unit</i>                                 |
| HH        | Polarização horizontal                                      |
| IW        | <i>Wide Interferometric</i>                                 |
| kNN       | <i>k-Nearest Neighbors</i>                                  |
| LSTM      | <i>Long Short Term Memory</i>                               |
| MF        | Maturação do Frutos   |
| ML        | <i>Machine Learning</i>                                     |
| MODIS     | <i>Moderate-Resolution Imaging Spectroradiometer</i>        |
| MSI       | <i>MultiSpectral Imager</i>                                 |
| MWW       | <i>Teste Mann-Whitney-Wilcoxon</i>                          |
| NDBI      | <i>Normalized Difference Built-up Index</i>                 |
| NDVI      | <i>Normalized Difference Vegetation Index</i>               |
| RADAR     | <i>Radio Detection and Ranging</i>                          |
| RAR       | Radar de Abertura Real                                      |
| ratioVVVH | Razão entre as polarizações VV e VH                         |
| RKN       | Root-knot nematodes   |
| NIR       | Região do infravermelho próximo no espectro eletromagnético |
| REM       | Radiação eletromagnética                                    |
| RF        | <i>Random Forest</i>  |
| RNA       | Redes Neurais Artificiais                                   |

---

|            |   |
|------------|---|
| RNR        | Redes Neurais Recorrentes                               |
| RVI        | <i>Radar Vegetation Index</i>                           |
| SAR        | <i>Synthetic Aperture Radar</i>                         |
| SG         | <i>Savitzky-Golay</i>                                   |
| SNAP       | <i>Sentinel Application Platform</i>                    |
| SHAP       | <i>Shapley Additive exPlanations</i>                    |
| SLC        | <i>Single Look Complex</i>                              |
| SM         | <i>Stripmap</i>   |
| SPOT       | <i>Satellite Pour l'Observation de la Terre</i>         |
| SRTM       | <i>Shuttle Radar Topography Mission</i>                 |
| subVVVH    | Subtração entre as polarizações VV e VH                 |
| sumVVVH    | Soma das polarizações VV e VH                           |
| SVM        | <i>Support Vector Machine</i>                           |
| SWIR       | Infravermelho de ondas curtas                           |
| VG         | Vegetativo  |
| VH         | Polarização cruzada                                     |
| VV         | Polarização Vertical                                    |
| WV         | <i>Wave</i>   |
| $\sigma^0$ | Coefficiente de retroespalhamento – <i>sigma nought</i> |
| $\rho$     | Reflectância de superfície                              |
| $\beta^0$  | <i>beta nought</i>                                      |
| $\gamma$   | gamma   |

---

## SUMÁRIO

|   |    |
|---|----|
| INTRODUÇÃO.....   | 1  |
| 1.1 Apresentação do problema.....   | 1  |
| 1.2 Estado da Arte.....   | 3  |
| 1.3 Hipótese .....  | 5  |
| 1.4 Objetivos.....  | 6  |
| 1.5 Contribuições Científicas.....  | 6  |
| 1.6 Estrutura da Tese .....   | 7  |
| REFERÊNCIAS TEÓRICOS .....  | 8  |
| 2.1 A cultura do cafeeiro.....  | 8  |
| 2.1.1 Aspectos fisiológicos do crescimento e produção do cafeeiro .....   | 8  |
| 2.1.2 Nematoides na cultura cafeeira .....  | 10 |
| 2.1.3 Cafeicultura no Cerrado Mineiro.....  | 11 |
| 2.2 Fundamento teóricos do Sensoriamento Remoto Óptico e SAR.....   | 13 |
| 2.2.1 Sensoriamento remoto óptico .....   | 13 |
| 2.2.2 Sensoriamento remoto por micro-ondas.....   | 14 |
| 2.2.3 Sensoriamento Remoto na Agricultura.....  | 22 |
| ÁREA DE ESTUDO E ESCOPO METODOLÓGICO .....  | 32 |
| 3.1 Material.....   | 32 |
| 3.1.1 Área de estudo .....  | 32 |
| 3.1.2 Dados de referência .....   | 33 |
| 3.1.3 Dados ópticos e SAR Sentinel.....   | 35 |
| 3.2 Abordagem metodológica.....   | 37 |
| 3.2.1 Pré-processamentos aplicados aos dados Sentinel .....   | 37 |
| 3.2.2 Registro das imagens Sentinel e geração de atributos espectrais e polarimétricos<br>41                    | 41 |
| 3.2.3 Potencial de dados Sentinel na detecção de nematoides .....   | 42 |
| EXPERIMENTOS.....   | 44 |
| 4.1 Experimento 1: Séries temporais de atributos ópticos e SAR para detecção de<br>nematoides no cafeeiro ..... | 44 |
| 4.1.1 Contextualização .....  | 44 |
| 4.1.2 Metodologia.....  | 45 |
| 4.1.3 Resultados e discussões .....   | 50 |
| 4.1.4 Potencial de séries temporais de atributos ópticos e SAR na detecção de<br>nematoides no cafeeiro .....   | 66 |
| 4.2 Experimento 2: Detecção de áreas de infestação por nematoides por meio de rede<br>BiLSTM.....               | 68 |

---

|                                |   |     |
|--------------------------------|---|-----|
| 4.2.1                          | Contextualização .....  | 68  |
| 4.2.2                          | Metodologia.....  | 69  |
| 4.2.3                          | Resultados e Discussões .....   | 76  |
| 4.2.4                          | Considerações sobre a utilização de rede BiLSTM para detecção de áreas infestadas por nematoides..... | 95  |
| 4.3                            | Análise comparativa entre os experimentos .....   | 97  |
| CONCLUSÃO E RECOMENDAÇÕES..... |   | 99  |
| REFERÊNCIAS .....              |   | 102 |

---

## Capítulo 1

### INTRODUÇÃO

#### 1.1 Apresentação do problema

A agricultura tem participação significativa na economia brasileira, sendo a principal responsável pela balança comercial positiva do país. Nesse cenário, o Brasil se destaca entre os maiores produtores e exportadores de cana-de açúcar, laranja e café (KLEIN; LUNA, 2023; MARTINELLI *et al.*, 2010; PICOLI *et al.*, 2018; UTRILLA-CATALAN *et al.*, 2022). Dentre esses, o café é a mais importante *commoditie* agroindustrial da economia nacional, além de ser a segunda *commoditie* mais comercializada no mundo (BARATA *et al.*, 2023; BENTO *et al.*, 2023). No Brasil, o estado de Minas Gerais é responsável por, aproximadamente, 55% da produção nacional de café (BARBOSA *et al.*, 2021; CONAB, 2022). Entretanto, diversos fatores são responsáveis pela redução da produtividade, especialmente patógenos que causam doenças ou parasitam as plantas, como os nematoides, especialmente *Meloidogyne spp.* (MARTINS; GALO; VIEIRA, 2017).

Os nematoides estão entre os patógenos com maior potencial destrutivo já que ocorrem no sistema radicular da planta, afetando o desenvolvimento do cafeeiro por reduzir a capacidade da raiz em absorver água e nutrientes, com subsequente queda da produtividade e até mesmo a morte das plantas. Embora tenham baixa mobilidade, esses patógenos têm alta capacidade reprodutiva e fácil disseminação por meio de implementos agrícolas. Os métodos tradicionais de diagnose de nematoides em uma lavoura envolvem a coleta de amostras de solo e raízes, seguido de análise laboratorial para identificação e quantificação dos nematoides. No entanto, esse método de diagnóstico, apesar de ser amplamente adotado, é dispendioso e ineficiente por necessitar de um grande número de amostras de solo para diagnosticar toda a área produtora (ŽIBRAT *et al.*, 2021).

Nos últimos anos, os avanços tecnológicos na área de sensoriamento remoto têm oferecido grandes contribuições no fornecimento de informações confiáveis sobre a disseminação de patógenos em culturas agrícolas, as quais podem superar as limitações dos métodos convencionais de detecção de nematoides na cultura do cafeeiro. O sensoriamento remoto pode auxiliar na redução do impacto ambiental e nos custos de aplicação de produtos fitossanitários, uma vez que o controle de doenças pode ser realizado de maneira direcionada (SANKARAN *et al.*, 2010). Além disso, fornece subsídios para a proposição de estratégias que minimizem prejuízos futuros.

---

A detecção de doenças em culturas agrícolas por meio do sensoriamento remoto tem ampla utilização pelo fato de plantas infectadas apresentarem resposta espectral diferente de plantas saudáveis, especialmente nas regiões do infravermelho próximo (NIR), vermelho limítrofe (*red-edge*) e infravermelho de ondas curtas (SWIR) (ZHANG *et al.*, 2003). Muitos estudos têm demonstrado que o sensoriamento remoto pode ser utilizado para detecção de patógenos do cafeeiro, tais como, a ferrugem (CHEMURA *et al.*, 2018; CHEMURA; MUTANGA; DUBE, 2017b; KATSUHAMA *et al.*, 2018; MARIN *et al.*, 2019; VELÁSQUEZ *et al.*, 2020), necrose dos frutos (MIRANDA *et al.*, 2020) e nematoides. Para o caso específico de nematoides, Martins; Galo; Vieira (2017) alcançaram índice kappa de 0,71 no mapeamento do patógeno utilizando as bandas espectrais do vermelho, *red-edge*, infravermelho próximo e NDVI do *RapidEye*. Além disso, os autores destacam que ocorrem diferenças significativas entre as características espectrais do cafeeiro para diferentes níveis de infecção por nematoides.

Algumas características específicas da cultura do cafeeiro, como seu ciclo fenológico bianual (sucessão de fases vegetativas e reprodutivas, que ocorrem em aproximadamente 2 anos) e seu plantio realizado geralmente em relevos mais acidentados, dificultam não apenas o mapeamento e monitoramento das áreas de cultivo por sensoriamento remoto, mas principalmente a detecção de áreas infestadas por patógenos. No caso de nematoides, a detecção do patógeno é dificultada pelo fato de que nos estágios iniciais de infecção, não ocorrem sintomas visíveis na parte aérea da planta (MORALES-ARANIBAR *et al.*, 2023; SALGADO; CARNEIRO; DE PINHO, 2011). Características relacionadas com a fase fenológica da cultura, tipo de solo, uso e cobertura do solo antes do cultivo e o sistema de cultivo (irrigado ou sequeiro) do cafeeiro, também podem ter influência relevante na ocorrência e severidade da infecção por nematoides (SALGADO; CARNEIRO; DE PINHO, 2011). Além disso, a detecção de patógenos cujos sintomas se confundam com a ocorrência de vários tipos de estresse durante o ciclo da cultura ainda é um desafio em sensoriamento remoto.

É importante destacar que os trabalhos de (Chemura; Mutanga; Dube, 2017c; Katsuhama *et al.*, 2018b; Marin *et al.*, 2019b; Martins; Galo; Vieira, 2017; Miranda *et al.*, 2020b; Velásquez *et al.*, 2020b) não exploram o aspecto multitemporal da ocorrência do patógeno na cultura cafeeira. Trabalhos recentes têm mostrado que séries temporais podem melhorar o mapeamento e monitoramento de culturas agrícolas, e que informações temporais sobre o ciclo fenológico são essenciais para a aplicação adequada de fertilizantes e agrotóxicos (SAAD EL IMANNI; EL HARTI; PANIMBOZA, 2022; SOUZA *et al.*, 2019).

---

Grande parte dos trabalhos encontrados na literatura utilizam dados hiperespectrais e multiespectrais obtidos por sensores ópticos para detecção e monitoramento de patógenos em culturas agrícolas (DAS *et al.*, 2023; JING *et al.*, 2022; SHI *et al.*, 2022; VILELA *et al.*, 2023; XIAO *et al.*, 2022). Dados ópticos são dependentes de condições climáticas e de iluminação, porém o monitoramento de doenças em culturas agrícolas pressupõe a disponibilidade de imagens adquiridas sistematicamente e com baixa cobertura de nuvens (HUNT *et al.*, 2020a). O desenvolvimento de novos sensores, como por exemplo Sentinel-1 C-SAR (*Synthetic Aperture Radar*), embarcado na plataforma Sentinel-1 permite incorporar novos atributos (polarimétricos e decomposições polarimétricas) para avaliação das condições da vegetação, uma vez que os sensores radar podem operar em condições atmosféricas adversas. A diversidade de atributos que podem ser gerados a partir dos dados SAR e sua integração com, por exemplo, os dados registrados pelo sensor MSI (*MultiSpectral Imager*) embarcado na plataforma Sentinel-2 A/B têm grande potencial para monitorar culturas agrícolas (MERCIER *et al.*, 2019).

Diante do contexto exposto, foi desenvolvido um estudo para avaliar a contribuição de séries temporais de dados ópticos e SAR na discriminação do cafeeiro infectado por nematoides. Esse estudo se apoia na premissa que séries temporais de atributos ópticos e SAR extraídos de imagens orbitais possam capturar alterações no dossel da vegetação que permitam distinguir entre o cafeeiro sadio e infectado por nematoides.

## 1.2 Estado da Arte

Nesta seção, são apresentados alguns estudos desenvolvidos nos últimos anos relacionados ao uso de séries temporais de dados de sensoriamento remoto (óptico e SAR) para monitoramento e mapeamento de culturas agrícolas e seus patógenos. Assim, será apresentada uma breve descrição, em ordem cronológica, dos principais trabalhos encontrados na literatura.

Zhao *et al.* (2018) utilizaram séries temporais para prever a incidência do oídio do trigo (*Blumeria graminis f. sp. tritici*) utilizando séries temporais do índice *Normalized Difference Vegetation Index* (NDVI) de dados *Moderate-Resolution Imaging Spectroradiometer* (MODIS) e dados meteorológicos. Nesse estudo foram utilizadas árvores de decisão para discriminar o grau de infecção pela doença utilizando três fatores de previsão: situação de crescimento do trigo (NDVI), temperatura da superfície da terra e condições meteorológicas. Os principais apontamentos desse estudo referem-se ao impacto da resolução espacial e temporal na acurácia da detecção do oídio do trigo. Zhao *et al.* (2018) sugerem dados com maior resolução temporal para caracterização de mudanças entre diferentes fases de desenvolvimento da cultura.

Hornero *et al.* (2020), investigaram a aplicabilidade de dados multitemporais Sentinel-2 para o monitoramento da infecção de *Xylella fastidiosa* (*Xf*) na cultura da oliveira, e sugerem o uso de atributos que minimizam efeitos atmosféricos e contribuições do solo para o monitoramento mais efetivo de doenças e patógenos. Yamamoto *et al.* (2023) utilizaram imagens adquiridas por veículos aéreos não tripulados, entre os anos de 2018 e 2020, para monitorar as variações espaciais e temporais de uma área infestada pela podridão vermelha da raiz da soja, causada pelo patógeno *Calonectria ilicicola*. Nesse trabalho os autores destacam que o uso de séries temporais permitiu visualizar a expansão de uma área infestada pela podridão vermelha da raiz da soja, bem como a direção do avanço da doença.

Há vários estudos que utilizam sensoriamento remoto e algoritmos de aprendizagem de máquina para detecção de patógenos em culturas agrícolas (Tabela 1). Abordagens que utilizam aprendizagem de máquina têm emergido como uma ferramenta efetiva por oferecerem algoritmos mais eficazes do que os algoritmos de classificação tradicionais (paramétricos), permitindo que os agricultores tomem decisões mais assertivas sobre aplicação de fertilizantes e controle de pragas (AMARASINGAM *et al.*, 2022; BOUGUETTAYA *et al.*, 2023).

**Tabela 1** - Trabalhos relacionados ao uso de aprendizagem de máquina para detecção de patógenos em culturas agrícolas utilizando dados de sensoriamento remoto.

| Autor(es)                       | Cultura  | Patógeno   | Plataforma             | Método de análise | Acurácia (%) |
|---------------------------------|----------|--|------------------------|-------------------|--------------|
| Chemura, Mutanga e Dube (2017)  | Cafeeiro | Ferrugem ( <i>Hemileia vastatrix</i> )               | Sentinel-2             | RF                | 64           |
| Bi <i>et al.</i> (2020)         | Soja     | Podridão Vermelha da Raiz ( <i>Fusarium solani</i> ) | PlanetScope            | GRU               | >82          |
| Li <i>et al.</i> (2022)         | Trigo    | Podridão Vermelha da Raiz ( <i>Fusarium solani</i> ) | Sentinel-2 e MODIS     | KNN               | >79          |
| Navrozidis <i>et al.</i> (2022) | Oliva    | Estresses bióticos e abióticos                       | Sentinel-2             | Algoritmos de ML  | >62          |
| Negrisola <i>et al.</i> (2022)  | Soja     | Ferrugem ( <i>Phakopsora pachyrhizi</i> )            | Assinaturas espectrais | Algoritmos de ML  | >57,14       |

GRU = *Gated Recurrent Unit*, RF = *Random Forest*, KNN = *K - Nearest Neighbors*, SVM = *Support Vector Machine*

Fonte: Elaborado pelo autor.

O desenvolvimento de novos sensores que operam no espectro das micro-ondas, como os sistemas SAR, tem permitido a incorporação de novos atributos para avaliação das condições da vegetação. Dados SAR, ao contrário dos dados ópticos, são particularmente atrativos pois, além de sofrerem pouca interferência por nuvens, podendo adquirir dados em condições climáticas adversas, permitem a definição de atributos estruturais que utilizam a informação

polarimétrica. Vários trabalhos que utilizam dados SAR no monitoramento de culturas agrícolas são encontrados na literatura (Tabela 2).

**Tabela 2** - Trabalhos que utilizam dados SAR para detecção de pestes e doenças em culturas agrícolas.

| <b>Autor(es)</b>                                 | <b>Cultura</b> | <b>Objeto da detecção</b>  | <b>Dados</b>              | <b>Atributos</b>    |
|--|----------------|----------------------------|---------------------------|---------------------|
| Singh; São; Singh, (2007)                        | Sorgo          | Danos causados por insetos | Banda X                   | HH e VV             |
| Toh <i>et al.</i> (2019)                         | Dendê          | Podridão basal             | ALOS-PALSAR 3/<br>Banda L | HH, HV e VV         |
| Li; Li e Liu, (2019)                             | Arroz          | Metais pesados             | Radarsat-2/Banda C        | HV, VH, VV, HH      |
| Lakmal <i>et al.</i> (2019)                      | Arroz          | Danos causados por insetos | Sentinel-1/Banda C        | VV, VH, matriz GLCM |
| Alebele <i>et al.</i> (2020)                     | Arroz          | Biomassa                   | Sentinel-1/Banda C        | VV, VH, índices SAR |
| Hashim <i>et al.</i> (2021)                      | Palma          | Podridão basal             | ALOS-PALSAR 2             | HH E HV             |
| Hernández; Borges; Francisco-Bethencourt, (2022) | Trigo          | Alumínio no solo           | Sentinel-1/Banda C        | VV, VH              |

*HH = polarização horizontal; VV = polarização vertical e VH = polarização cruzada.*

Fonte: Elaborado pelo autor.

### 1.3 Hipótese

Séries temporais de atributos ópticos são amplamente utilizadas no monitoramento de patógenos em culturas agrícolas. No caso dos nematoides, patógenos que parasitam o sistema radicular da planta durante todo o ciclo da cultura, a infecção é detectada quando ocorrem mudanças estruturais na parte aérea da planta. Diante disso, alterações no comportamento sazonal da planta podem ser monitoradas a partir de séries temporais de atributos extraídos de imagens de sensoriamento remoto. Contudo, devido aos problemas inerentes de aquisição de séries temporais regulares de dados ópticos, os dados SAR são particularmente atrativos por sofrerem pouca influência de condições atmosféricas adversas e por capturarem variações estruturais no dossel da vegetação. Além disso, a combinação de dados ópticos e SAR pode fornecer informações valiosas para monitoramento agrícola, uma vez que dados ópticos detectam variações que ocorrem na composição bioquímica da vegetação, enquanto os dados SAR são sensíveis a estrutura e fenologia da planta. Considerando o exposto, a hipótese deste estudo é que: “*Séries temporais de atributos ópticos e SAR permitem a discriminação de áreas*

---

*infestadas por nematoides, em fases fenológicas específicas do ciclo de desenvolvimento do cafeeiro”.*

#### **1.4 Objetivos**

O objetivo geral desta pesquisa foi investigar o potencial de séries temporais de dados ópticos e SAR em detectar áreas infestadas por nematoides na cultura cafeeira, em diferentes fases fenológicas do cafeeiro. Para isso, foram propostos os seguintes objetivos específicos:

- Caracterizar os padrões fenológicos do cafeeiro sadio e infectado por nematoides a partir de séries temporais de atributos ópticos e SAR;
- Avaliar a capacidade de séries temporais de atributos ópticos e SAR na discriminação de áreas sadias e áreas infestadas;
- Identificar as fases fenológicas que favoreçam a discriminação de áreas infestadas por nematoides;
- Avaliar a capacidade de redes *Bi-directional Long Short Term Memory* (BiLSTM) na detecção de nematoides a partir de séries temporais de dados ópticos e SAR.

#### **1.5 Contribuições Científicas**

Esse trabalho se propõe a desenvolver um estudo para avaliar a capacidade de séries temporais de dados ópticos e SAR na discriminação do cafeeiro infectado por nematoides. Em diversos trabalhos é mencionado que o aumento de observações por meio da integração de sensores permite alcançar resultados com melhor desempenho quando comparado com o uso de um único sensor (BERGER *et al.*, 2022; URBAZAEV *et al.*, 2018). No entanto, o uso de multisensores para o monitoramento de patógenos da cultura cafeeira ainda é pouco explorado na literatura, em razão da complexidade espectral dessa cultura. No caso do cafeeiro, o solo, o sombreamento intra e entre as linhas de plantio, além das características sazonais da cultura, influenciam na resposta espectral do cafeeiro (EPIPHÂNIO; LEONARDI; FORMAGGIO, 1994). Portanto, é evidente a necessidade de estudos para subsidiar o desenvolvimento de métodos apropriados e confiáveis de monitoramento de áreas cafeeiras.

Diferente das abordagens comumente utilizadas para monitoramento de culturas agrícolas, essa pesquisa propõe investigar o comportamento sazonal de áreas infestadas por nematoides preliminarmente à aplicação de métodos de detecção. Este estudo é pautado pelo fato de que, ao observar as interações entre o agente patogênico e o hospedeiro, diferentes doenças e patógenos causam uma variedade de sintomas e danos nas plantas, o que constitui

---

uma base física para o monitoramento a partir de sensoriamento remoto. Outro ponto a ser considerado, e que muitas vezes não é explorado, é que a ocorrência e severidade de uma doença ou patógeno se comporta como um processo temporal, de modo que diferentes sintomas podem se sobrepor ou interagir entre si, e se manifestarem com diferentes intensidades ao longo do ciclo fenológico da cultura. Nesta perspectiva, é proposta uma análise de todo o ciclo de desenvolvimento da cultura a partir de atributos extraídos de séries temporais de atributos ópticos e SAR, com o objetivo de identificar as fases fenológicas mais adequadas à discriminação de áreas saudas e infestadas por nematoides. Destaca-se que padrões temporais de ocorrência de doenças/patógenos podem permitir a extração de atributos temporais que auxiliem na redução da incerteza do monitoramento de doenças em culturas agrícolas.

Por fim, vários grupos de trabalho (GP) da ISPRS (*International Society for Photogrammetry and Remote Sensing*) trazem vários termos de referência relacionados com o tema desta pesquisa. O GP 3 (*Active Microwave Remote Sensing*) da comissão III (*Remote Sensing*) apresenta dentre seus termos referência a avaliação do potencial de futuros ou novos sistemas de radar. Por sua vez, o GP 9 (*Agriculture and Natural Ecosystems Modelling and Monitoring*) promove o desenvolvimento de novas metodologias e algoritmos para melhorar a contribuição do sensoriamento remoto para a agricultura e os ecossistemas naturais, além da utilização do sensoriamento remoto como apoio à agricultura de precisão, com base na assinatura espectral de culturas, para o gerenciamento de *smarts farms*.

## **1.6 Estrutura da Tese**

Essa tese está organizada em 5 capítulos. No primeiro capítulo é contextualizado o tema de pesquisa, seguido da hipótese, objetivos, justificativa e contribuições. O Capítulo 2 introduz alguns aspectos teóricos, essenciais para entendimento do trabalho desenvolvido, principalmente aqueles relacionados a cultura do cafeeiro (*Coffea* sp.). No Capítulo 3 faz-se uma caracterização das áreas de estudos e dos dados utilizados como referência, além de apresentar os processamentos aplicados aos dados SAR e ópticos até a geração dos atributos avaliados temporalmente. O Capítulo 4 apresenta os experimentos realizados para atingir os objetivos desta tese, além dos resultados e considerações de cada experimento. Por fim, no Capítulo 5, são apresentadas as conclusões e recomendações para trabalhos futuros.

---

## Capítulo 2

### REFERÊNCIAS TEÓRICOS

Esse capítulo tem por objetivo introduzir alguns pontos essenciais para entendimento dessa pesquisa, principalmente aqueles relacionados a cultura do cafeeiro (*Coffea* spp.)

#### 2.1 A cultura do cafeeiro

O cafeeiro é uma planta perene, dicotiledônia, de porte arbustivo e flores andróginas (hermafroditas). Além disso, pertence à família Rubiaceae, gênero *Coffea*, sendo que as duas espécies mais cultivadas desse gênero são *Coffea arabica* (café arábica) e *Coffea canephora* (Café conilon) (CARVALHO, 2008).

Segundo Ferreira *et al.* (2022), o café arábica é uma espécie que apresenta dimorfismo de ramos, ou seja, formação de dois tipos de ramos com funções diferentes. Os ramos ortotrópicos são ramos vegetativos e improdutivos que crescem verticalmente e formam hastes ou troncos. Sua função é sustentar os ramos produtivos. Os ramos plagiotrópicos são ramos produtivos, nos quais se formam os botões florais e, conseqüentemente, as flores e os frutos. O café conilon é uma espécie alógoma, que depende da movimentação dos ventos e de insetos para que ocorra a polinização, além disso também apresenta dimorfismo de ramos. Contudo, essa espécie apresenta vários caules (multicaule), o que possibilita a obtenção de maior produtividade.

O café arábica é predominante em regiões com temperaturas médias anuais entre 18° C e 22° C. Altas temperaturas causam aborto das flores, diminuindo a produtividade. Em locais com temperaturas muito baixas, a ocorrência de geadas pode ser prejudicial para o cultivo do cafeeiro. Já o café conilon é adaptado ao clima úmido e as regiões com temperaturas médias anuais entre 22° C e 26° C são ideais para o cultivo dessa cultivar (FERRÃO e RIVA-SOUZA, 2021).

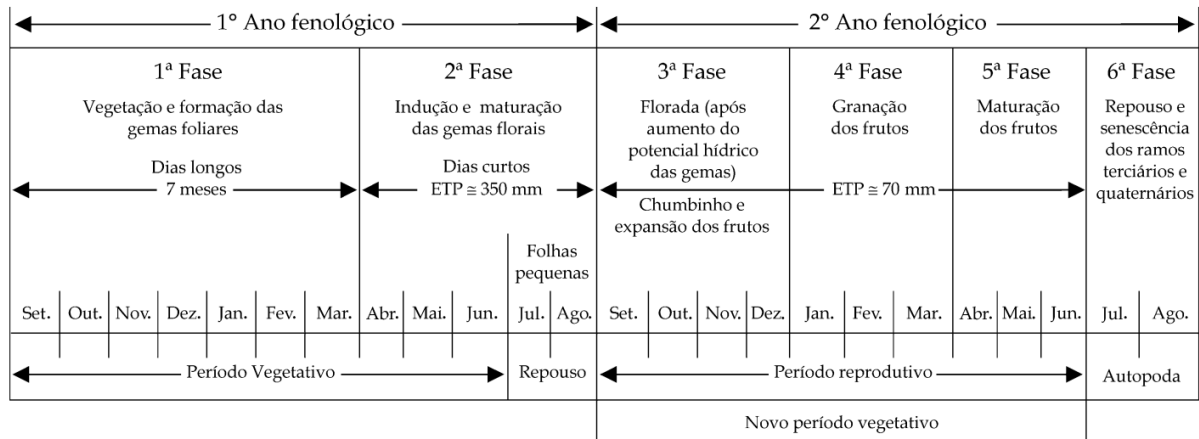
##### 2.1.1 Aspectos fisiológicos do crescimento e produção do cafeeiro

Um dos problemas nas regiões produtoras de café refere-se à variabilidade espacial e temporal da produtividade das plantas, sendo muito comum, nas lavouras cafeeiras, plantas sem produção ao lado de plantas produtivas, bem como a bienalidade da produção. O efeito de bienalidade é considerado um fenômeno da alternância de grandes e pequenas produções ao longo do tempo (MENDONÇA *et al.*, 2011).

A bienalidade da produção do cafeeiro é explicada pela concorrência entre as funções vegetativas e reprodutivas. Nos anos de grande produção, o crescimento dos frutos demanda a maior parte da atividade metabólica da planta, reduzindo o desenvolvimento vegetativo. Como no cafeeiro

arábica o fruto se desenvolve nas partes novas dos ramos do ano anterior há, conseqüentemente, uma produção menor. O ciclo fenológico dos cafeeiros da espécie *Coffea arabica* apresenta uma sucessão de fases vegetativas e reprodutivas, que ocorrem em aproximadamente 2 (dois) anos. Na Figura 1, é apresentado um esquema das fases fenológicas do café arábica.

**Figura 1** – Esquemática das fases fenológicas do cafeeiro para o período de 24 meses.



Fonte: Camargo e Camargo (2001).

Na primeira fase do primeiro ano fenológico, ocorre o período vegetativo e formação das gemas florais. Esses períodos são dependentes da condição fotoperiódica, ocorrendo de setembro a março, em dias longos. Na segunda fase ocorre a indução e maturação das gemas florais, as quais ocorrem em dias curtos, de abril a agosto, e são dependentes de condição fotoperiódica. No fim dessa segunda fase, em julho-agosto, as plantas entram em repouso (CAMARGO e CAMARGO, 2001).

A terceira fase, início do segundo ano fenológico, começa com a florada, chumbinho e expansão dos frutos. Essa etapa compreende quatro meses, de setembro a dezembro. A quarta fase é a granação dos frutos, quando os líquidos internos se solidificam e ocorre a formação aos grãos no verão, de janeiro a março. A maturação dos frutos se dá na quinta fase, compreendendo normalmente os meses de abril, maio e junho. Nessa etapa, a evapotranspiração potencial decresce significativamente e as deficiências hídricas moderadas beneficiam a qualidade do produto. Na sexta etapa, de julho a agosto, ocorre a senescência onde muitos ramos produtivos secam e morrem, limitando o crescimento do cafeeiro, definindo a chamada autopoda (CAMARGO e CAMARGO, 2001).

De acordo com Camargo e Camargo (2001), há diversas formas de esquematizar as fases fenológicas do cafeeiro, incluindo modelos que consideram quatro, seis, sete e oito fases. Diante disso, nesta pesquisa foi considerado o modelo de 4 fases (12 meses), de modo a facilitar a compreensão da fenologia do cafeeiro a partir da dados de sensoriamento remoto. Segundo Camargo (1998), as fases do cafeeiro, considerando o período de 12 meses, podem ser descritas

da seguinte forma: (1) formação dos grãos entre janeiro e abril; (2) maturação dos frutos de abril a julho; (3) autopoda entre os meses de julho e agosto; e (4) vegetativa de setembro a dezembro (Figura 2).

**Figura 2** – Esquemática das fases fenológicas do cafeeiro para o período de 12 meses.



Fonte: Camargo (1998).

### 2.1.2 Nematoides na cultura cafeeira

Entre as doenças que limitam a produção cafeeira, aquelas causadas por nematoides assumem grande importância em virtude dos sérios prejuízos causados, face às dificuldades de controle (CARNEIRO, 2017). Os nematoides são microrganismos do solo capazes de parasitar o sistema radicular da planta durante praticamente todo o ciclo de desenvolvimento da cultura (SALGADO; CARNEIRO; PINHO, 2011). Além disso, são limitantes ao cultivo do cafeeiro, principalmente em solos arenosos, com baixa fertilidade e deficiência hídrica (OLIVEIRA e ROSA, 2018). Em todo o mundo, os nematoides estão entre os principais parasitas que reduzem a produtividade do café (MEKETE *et al.*, 2008).

Diversas espécies de nematoides têm sido encontradas associadas às raízes de cafeeiros no Brasil, sendo as espécies dos gêneros *Meloidogyne* e *Pratylenchus* as mais prejudiciais à cafeicultura (SALGADO; CARNEIRO; PINHO, 2011). Os nematoides do gênero *Meloidogyne* spp, principalmente *Meloidogyne exigua*, *Meloidogyne paranaensis* e *Meloidogyne incognita* são as espécies mais prejudiciais devido à ampla distribuição geográfica e à intensidade dos danos que causam (TERRA *et al.*, 2018).

No Brasil, a ocorrência dos nematoides é mais grave em regiões de solos arenosos dos estados de São Paulo, Paraná e Minas Gerais (GHINI *et al.*, 2008). Os sintomas de ocorrência incluem necrose radicular, que reduz a absorção de água e nutrientes pela planta e contribui para a diminuição da produtividade e até a morte da planta (GHINI *et al.*, 2008). Nas raízes afetadas, os sintomas característicos são engrossamento da raiz principal no local de instalação dos nematoides, seguido do

---


aparecimento de rachaduras longitudinais, favorecendo a penetração de outros microrganismos (GARCIA; COSTA; RODRIGUES, 2000). As folhas podem ficar com coloração anormal, cloróticas, semelhante a sintomas de deficiência nutricional. Com isso, ocorre diminuição na produção, inviabilizando a exploração econômica.

### **2.1.3 Cafeicultura no Cerrado Mineiro**

No cenário nacional, o estado de Minas Gerais é o maior produtor de café, sendo também responsável por mais da metade da área plantada. Entre as regiões de Minas Gerais, a do Cerrado Mineiro é uma das prioritárias no incentivo à cafeicultura nacional (ORTEGA; DE JESUS; MOURO, 2009). O Cerrado Mineiro é constituído por 55 municípios distribuídos nas regiões do Triângulo Mineiro, Alto Paranaíba e Noroeste (FEDERAÇÃO DO CERRADO MINEIRO, 2023). Dentre os 55 municípios, destacam-se as cidades de Patrocínio, Monte Carmelo, Araguari, Patos de Minas, Campos Altos, Unaí, São Gotardo, Serra do Salitre, Araxá e Carmo do Paranaíba como as principais produtoras.

A região do Cerrado Mineiro é produtora do café do tipo arábica, ou café de altitude, reúne 4500 produtores numa área de cultivo de 210 mil hectares, produzindo, aproximadamente 5 milhões de sacas/ano, o que deixa a região com participação de 12,7% na produção brasileira e 25,4% na produção mineira (REGIÃO DO CERRADO MINEIRO, [s.d.]). O que agrega valor ao café do Cerrado Mineiro, é a certificação de qualidade e a indicação geográfica. Em 2005, o Instituto Nacional de Propriedade Industrial (INPI) atribuiu ao café do Cerrado Mineiro a Indicação de Procedência (IP) e em 2013 a Denominação de Origem (DO). Tanto o selo DO como o IP são indicações geográficas, que mostram que o produto possui qualidades e/ou características que dependem exclusiva ou essencialmente do ambiente geográfico no qual ele é produzido (SANTANA, 2022).

A Figura 3 apresenta os dados referentes à produção de café entre os anos de 1990 e 2021 na região do Cerrado Mineiro (Triângulo Mineiro/Alto Paranaíba e Noroeste). De acordo com o gráfico, percebe-se um crescimento na produção no decorrer dos anos na região do Triângulo Mineiro. Entretanto, para a região do Noroeste de Minas a produção se manteve estável. Além disso, é perceptível o efeito de bienalidade da cultura no volume de produção.

**Figura 3** - Série histórica da produção (toneladas) de café no Cerrado Mineiro de 1990 a 2021.

Fonte: IBGE (2023).

Os dez maiores produtores de café do Cerrado Mineiro estão apresentados na Tabela 3, considerando a área destinada a colheita e a quantidade produzida. A soma da quantidade produzida nos maiores produtores do Cerrado Mineiro representa em média 12,91% da quantidade produzida em Minas Gerais em 2017 e 15,46% em 2018. Além disso, o estado de Minas Gerais representou 54,19% do total produzido no Brasil em 2017 e 53,44% em 2018. Tais dados reforçam a característica bienal da cultura na região do Cerrado Mineiro, ao mesmo tempo que evidenciam a sua capacidade produtiva. A Tabela 3 também deixa evidente o crescimento da área colhida em conjunto com o crescimento da produção.

**Tabela 3** - Área destinada a colheita e quantidade produzida nos anos de 2020 e 2021 no Brasil, Minas Gerais e nos dez maiores produtores de café do Cerrado Mineiro.

| Brasil, Unidade da Federação e Município | Área destinada à colheita (Hectares) |                  | Quantidade produzida (Toneladas) |                  |
|--|--------------------------------------|------------------|----------------------------------|------------------|
|  | 2020                                 | 2021             | 2020                             | 2021             |
| <b>Brasil</b>                            | <b>1.907.554</b>                     | <b>1.837.833</b> | <b>3.706.583</b>                 | <b>2.993.780</b> |
| <b>Minas Gerais</b>                      | <b>1.054.911</b>                     | <b>1.002.787</b> | <b>2.064.689</b>                 | <b>1.359.828</b> |
| Patrocínio                               | 43.595                               | 42.092           | 76.204                           | 60.486           |
| Serra do Salitre                         | 19.350                               | 17.150           | 34.830                           | 25.170           |
| Monte Carmelo                            | 13.600                               | 15.750           | 26.928                           | 28.350           |
| Rio Paranaíba                            | 13.462                               | 12.745           | 24.486                           | 13.765           |
| Carmo do Paranaíba                       | 11.710                               | 10.760           | 22.805                           | 16.582           |
| Araguari                                 | 11.330                               | 11.760           | 22.433                           | 21.874           |
| Campos Altos                             | 9.435                                | 8.330            | 19.814                           | 9.996            |
| Patos de Minas                           | 8.980                                | 9.125            | 17.437                           | 15.717           |
| Coromandel                               | 8.820                                | 8.230            | 16.043                           | 10.287           |
| Perdizes                                 | 7.690                                | 7.030            | 15.771                           |                  |

Fonte: IBGE (2023).

## 2.2 Fundamento teóricos do Sensoriamento Remoto Óptico e SAR


### 2.2.1 Sensoriamento remoto óptico

O sensoriamento remoto óptico orbital tem fornecido dados da superfície terrestre por mais de quatro décadas. Alguns sistemas com grande e consistente disponibilidade de dados têm facilitado a observação da superfície terrestre, tais como Landsat desde 1972, *Satellite Pour l'Observation de la Terre* (SPOT) desde 1980 e o MODIS desde 1999. Os sensores ópticos instalados nessas plataformas orbitais obtêm imagens simultaneamente de uma mesma área da superfície terrestre em várias regiões do espectro eletromagnético, realizando o imageamento multiespectral nas regiões do visível (450 - 700 nm), infravermelho próximo (NIR – *Near Infrared*, 700-1500 nm), infravermelho de ondas curtas (SWIR – *Short-Wave Infrared*, 1500 – 3000 nm) e infravermelho termal (TIR – *Thermal Infrared*, 10,6 – 11,9  $\mu\text{m}$ ) (JENSEN, 2014).

A radiação eletromagnética (REM) incidente sobre um alvo pode ser refletida, absorvida ou transmitida. A interação da REM com os diferentes constituintes de um alvo define a assinatura espectral específica para cada alvo (Figura 4), a qual é utilizada para discriminação dos alvos em imagens multiespectrais. Em dados ópticos, é a reflectância a grandeza radiométrica que representa características intrínsecas ao alvo e, dessa forma, é utilizada para caracterizar o comportamento espectral do alvo. Essa grandeza radiométrica é dada pela razão entre o fluxo radiante refletido ( $\Phi_{refletido\lambda}$ ) e o fluxo incidente ( $\Phi_{i\lambda}$ ) ao alvo (JENSEN, 2014) (Equação 1).

$$\rho_{\lambda} = \frac{\Phi_{refletido\lambda}}{\Phi_{i\lambda}} \quad (1)$$

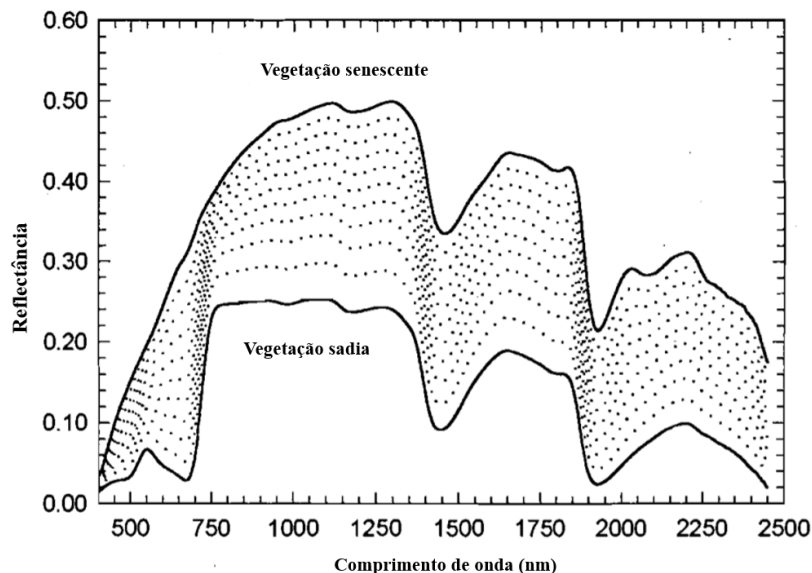
**Figura 4** – Espectros de reflectância dos alvos.



Fonte: Adaptado de Jensen (2014).

O comportamento espectral da vegetação sadia é caracterizado por duas regiões de absorção na região do visível entre 450 e 520 nm e 630 e 690 nm, associadas à absorção pelos pigmentos fotossintéticos (clorofila e carotenoides). Na região do infravermelho próximo, entre 700-1500 nm, a vegetação sadia apresenta alta reflectância. Na região do infravermelho de ondas curtas, entre 1500 e 2500 nm, a reflectância é dominada pelas feições de absorção da água, dessa forma quanto maior a quantidade de água contida na folha menor a reflectância (JENSEN, 2014). Quando a vegetação está em processo de senescência (Figura 5), há redução no teor de clorofila e, conseqüentemente, aumento na reflectância nas regiões entre 450 e 650 nm. Essas modificações ocorrem devido a redução das feições de absorção da água e às alterações estruturais que ocorrem na folha pela perda de umidade. O platô na região do NIR (700-1450 nm), observado na vegetação sadia, é modificado com o aumento da senescência.

**Figura 5** - Espectros de refletância da vegetação sadia e senescente.



Fonte: Adaptado de Ustin (2004).

Conhecendo o comportamento espectral dos alvos é possível realçar alvos específicos em imagens, a partir de operações aritméticas entre bandas espectrais, definindo índices espectrais. Dentre os índices espectrais mais utilizados em sensoriamento remoto tem-se o NDVI que utiliza a banda do vermelho e do NIR para realce da vegetação e o *Normalized Difference Built-up Index* (NDBI) que utiliza das bandas do SWIR e do NIR para realce de áreas impermeáveis.


### 2.2.2 Sensoriamento remoto por micro-ondas

Os sensores remotos que operam na região das micro-ondas podem ser classificados em passivos, como radiômetros, e em ativos, como os sensores radar (ULABY e LONG, 2014). O termo RADAR é um acrônimo de “*Radio Detection and Ranging*”, isto é, um sistema capaz de detectar alvos

a partir de sua distância e posição. Os sistemas radar são sensores que operam na região das micro-ondas (0,3-300 Ghz) e que possuem três funções básicas, (1) transmitir um pulso, na faixa das micro-ondas, na direção dos alvos; (2) receber o pulso retroespalhado pelo alvo e (3) registrar a intensidade do sinal recebido e o intervalo de tempo entre sua emissão e recepção (NOVO e PONZONI, 2001) (Figura 6). Considerando que a velocidade de propagação de uma onda eletromagnética é a velocidade da luz ( $c \approx 300.000.000\text{m/s}$ ) e que a distância entre o radar e o alvo é  $R$ , o tempo de ida e volta da onda eletromagnética é dado conforme Equação 2:

$$\tau = 2R/c \quad (2)$$

**Figura 6** - Princípio de imageamento do radar.



Fonte: Adaptado de Jensen (2014).

Na região das micro-ondas, assim como no espectro óptico, as frequências são divididas em bandas, conforme apresentado na Tabela 4. Cada banda interage de modo diferente com os alvos, mais especificamente, com o tamanho e propriedades dielétricas do alvo. A banda C é adequada para monitoramento da vegetação, e a banda L é adequada para estudos florestais, cobertura da terra, monitoramento de desastres etc. A banda P, por possuir menor frequência, pode penetrar não apenas em florestas, mas também em solo seco, neve e gelo. As maiores frequências, como a banda X, se espalham na superfície dos alvos mas não os penetra (YAMAGUCHI, 2020).

**Tabela 4** - Comprimento de onda e frequência das bandas SAR.

| <b>Banda</b> | <b>Comprimento de onda (<math>\lambda</math> - cm)</b> | <b>Frequência (<math>\nu</math> - GHz)</b> |
|--------------|--|--|
| Ka           | 0,75 - 1,18  | 40,0 – 26,5                                |
| K            | 1,19 – 1,67  | 26,5- 18,0                                 |
| $K_u$        | 1,67 - 2,4   | 18,0 - 12,5                                |
| X            | 2,5 - 3,8  | 12,5 - 8,0                                 |
| C            | 3,9 - 7,50   | 8,0 - 4,0                                  |
| S            | 7,50 - 15,0  | 4,0 - 2,0                                  |
| L            | 15,0 - 30,0  | 2 - 1                                      |
| P            | 30,0 - 100,0   | 1 - 0,3                                    |

Fonte: Adaptado de Jensen (2014).

A energia retroespalhada em direção ao radar é o coeficiente de retroespalhamento ou sigma zero ( $\sigma^0$ ). O coeficiente de retroespalhamento é dado em função da seção transversal de radar ( $\sigma$ ) por unidade de área no terreno, é adimensional, e como seu valor pode ter grande variação é expresso como logaritmo, com unidades de decibéis (dB), que em geral variam de -5 a +40 dB (JENSEN, 2014). O sinal que chega ao radar pode ser representado por um número complexo, cuja parte real é a amplitude e a parte imaginária é a fase. A amplitude é a intensidade do sinal registrado e a defasagem do sinal de retorno é a fase. Dessa forma, o sinal do radar retroespalhado possui como atributos o comprimento de onda ( $\lambda$ ), a amplitude e a fase.

Os radares imageadores possuem sua própria fonte de energia, isto é, são sensores ativos. Por possuir sua própria fonte de energia, os sensores radares são independentes às condições de iluminação solar. Além disso, esses sensores têm as vantagens de penetração nas nuvens, menor influência dos efeitos atmosféricos, além de permitir a penetrabilidade nos alvos.


Os sistemas radar imageadores de interesse para o sensoriamento remoto diferenciam-se em função da antena utilizada, podendo ser de dois tipos: Radar de Abertura Real (*Real Aperture Radar* - RAR) e Radar de Abertura Sintética (*Synthetic Aperture Radar* - SAR). Os RARs possuem restrições causadas pelo tamanho da antena que pode ser acoplada, o que por sua vez afeta os comprimentos de onda utilizados, bem como a capacidade de manter a resolução espacial em faixas de operação muito longas. Os SARs são uma alternativa para superar esses problemas. O SAR usa uma antena relativamente curta, mas sintetiza uma antena maior aproveitando o movimento de avanço da plataforma na qual está embarcado (TREVETT, 1986). Ambos RAR e SAR possuem visada lateral e adquirem imagens de uma faixa contínua ao longo da trajetória do radar.

### 2.2.2.1 Imageamento SAR

Os sistemas radar são compostos por um emissor de energia (gerador de sinais ou pulsos), um receptor, uma antena e um *switch* para alternar a recepção e emissão dos sinais pela antena. Em um

pequeno intervalo de tempo, o *switch* aciona o módulo de emissão de energia permitindo que o emissor envie um sinal em direção ao alvo através da antena. No instante seguinte o *switch* é alterado, fazendo com que o sistema passe a funcionar como um sistema de captação de sinais, e os ecos do sinal emitido, refletidos pelo objeto, são registrados pela unidade receptora (JENSEN, 2014). O sinal captado é posteriormente amplificado e gravado (Figura 7).

**Figura 7** - Componentes de um sistema radar.



Fonte: Adaptado de Jensen (2014).

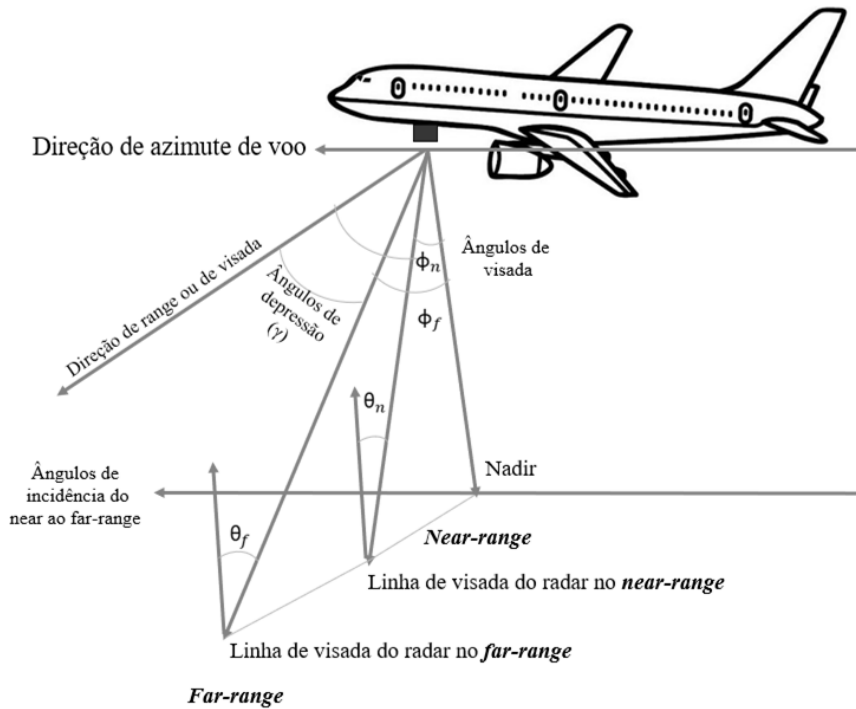
A relação fundamental entre as características do sistema radar, o alvo, e do sinal emitido pela antena, o qual interage com a superfície imageada e retorna para a antena, é representada pela seguinte equação:

$$P_R = P_T(\sigma^0 \cdot A) \cdot \frac{G^2 \cdot \lambda^2}{(4\pi)^3 \cdot R^4} \quad (3)$$

em que a potência do sinal recebido ( $P_R$ ) é diretamente proporcional à potência do sinal transmitido ( $P_T$ ), ao coeficiente de retroespalhamento do alvo ( $\sigma^0$ ), à área efetiva da abertura da antena ( $A$ ), ao ganho da antena ( $G$ ), ao comprimento de onda do radar ( $\lambda$ ) e a razão  $1 / (4\pi)^3 \cdot R^4$ , sendo  $R$  a distância entre o radar e o alvo, considerando a transmissão e a recepção da energia de forma isotrópica. O coeficiente de retroespalhamento ( $\sigma^0$ ), que é adimensional, está diretamente relacionado aos parâmetros do alvo, enquanto os demais termos da equação do radar se relacionam com os parâmetros do sensor.

Outros parâmetros adicionais sobre a natureza do pulso da energia de micro-ondas que é enviado da antena radar em direção ao terreno, incluem a direção de azimute de voo, direção de range ou de visada, ângulo de depressão, ângulo de visada, ângulo de incidência e polarização (Figura 8). Esses componentes são baseados em sensores radar embarcados em aeronaves, mas são igualmente aplicáveis a sistemas radar orbitais.

**Figura 8** - Geometria de um sistema SAR.

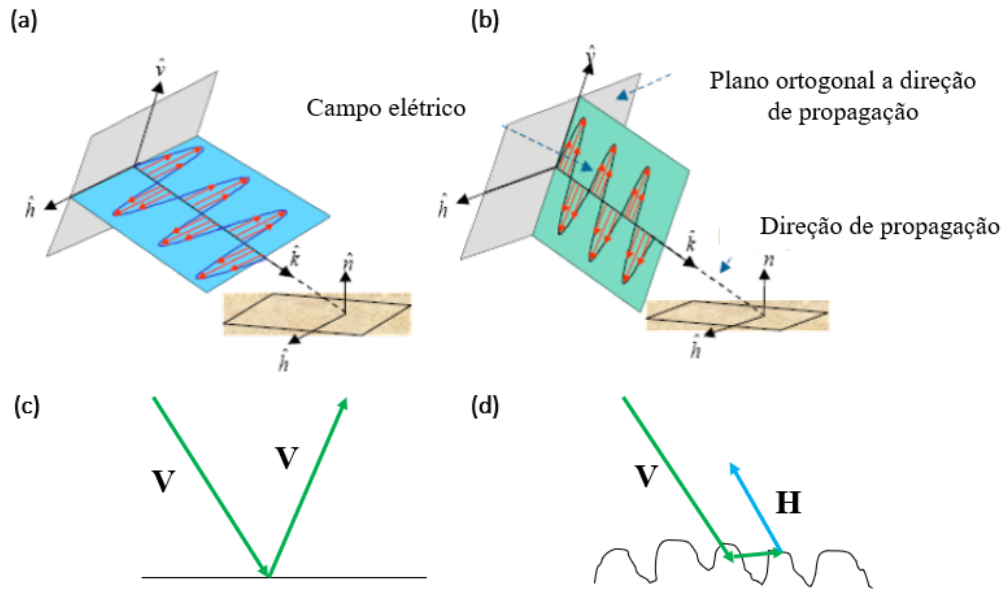


Fonte: Adaptado de Jensen (2014).

A direção de azimute de voo é a direção de voo da plataforma, a direção de visada é a direção de iluminação do radar e o ângulo de visada ( $\phi$ ) é o ângulo entre a vertical (nadir) da antena ao solo e a linha de visada do radar, o qual varia do *near-range* ao *far-range* e é o complemento do ângulo de depressão. Sendo o ângulo de depressão ( $\gamma$ ) o ângulo entre a direção de visada e a linha de visada. O ângulo de incidência ( $\theta$ ) é o ângulo com que o feixe incide na superfície.

A polarização dos sinais radar se refere à orientação do campo elétrico. As antenas do sistema radar enviam e recebem energia polarizada, que pode ser polarizada verticalmente (Figura 9a), ou polarizada horizontalmente (Figura 9b). Quando o sinal radar incide na superfície e é retroespalhado, a polarização pode ser modificada, segundo as propriedades da superfície. Quando o sensor emite um sinal e o recebe na mesma polarização, tem-se a co-polarização (VV ou HH) (Figura 9c), por outro lado, quando o sinal é emitido e, posteriormente, recebido em polarizações distintas tem-se a polarização cruzada (VH ou HV) (Figura 9d). As polarizações HH e VV estão relacionadas com a rugosidade da superfície (espalhamento superficial) e as polarizações cruzadas (HV e VH) com o espalhamento volumétrico.


**Figura 9** - Polarizações dos sinais radar: (a) polarização horizontal, (b) polarização vertical, (c) co-polarização vertical (VV) e (d) polarização cruzada (VH).



Fonte: Adaptado de Le Toan (2007).

Segundo Ulaby *et al.* (1981), as superfícies imageadas são classificadas de acordo com o padrão do retroespalhamento nas seguintes categorias: (i) lisa: quando a superfície reflete a energia incidente de forma especular, com ângulo de reflexão na direção oposta ao ângulo de incidência (Figura 10a); (ii) levemente rugosa: a energia é refletida de forma difusa pela superfície (Figura 10b); e (iii) rugosa: a energia incidente é retroespalhada em várias direções de forma homogênea (Figura 10c).

**Figura 10** - Padrão do retroespalhamento a partir da superfície imageada: (a) lisa, (b) levemente rugosa e (c) rugosa.




Fonte: Adaptado de Ulaby *et al.* (1981).

### 2.2.2.2 Distorções em imagens SAR

Distorções geométricas existem em quase todos sistemas radares imageadores, as quais incluem *foreshortening*, *layover* e *shadowing* (JENSEN, 2014). Quando o feixe do radar atinge a base de um alvo inclinado em direção ao radar antes de atingir o topo, ocorrerá um encurtamento de rampa (*foreshortening*), ou seja, como o radar mede a distância na faixa de inclinação, a inclinação (2)

aparecerá comprimida e o comprimento da inclinação será representado incorretamente (1) (Figura 11a). O *layover* (Figura 11b) ocorre quando o feixe radar atinge o topo de um alvo inclinado (B) antes de atingir a base (A), fazendo com que o sinal de retorno da parte superior do alvo seja recebido antes do sinal da parte inferior. Tanto o *foreshortening* quanto o *layover* resultam em sombreamento (*shadowing*), ocasionado quando o feixe radar não consegue iluminar a superfície do solo (Figura 11c).

**Figura 11** - Distorções geométricas em sistemas radares: (a) foreshortening em faixa inclinada, (b) layover em faixa inclinada e (c) shadow em faixa inclinada.



Fonte: Adaptado de *Radarsat Geology Handbook*.

### 2.2.2.3 Imagens SAR no estudo da vegetação

Desde a década de 1970, dados radar têm sido utilizados para estudos da vegetação. As imagens radar fornecem medidas que podem ser correlacionadas com alguns parâmetros biofísicos da vegetação, tais como: tipo da vegetação, teor de umidade, biomassa e estrutura do dossel (JENSEN, 2014). De modo similar aos dados ópticos, índices de vegetação derivados de imagens radar também podem ser uma alternativa no monitoramento e identificação de culturas agrícolas (LIU *et al.*, 2019), bem como no monitoramento de patógenos e doenças (ZHANG *et al.*, 2019). Na Tabela 5 é esquematizada a relação entre dados ópticos e SAR e variações na rugosidade da superfície do solo, densidade da vegetação e umidade do solo.

**Tabela 5** - Resposta teórica das medições ópticas e de SAR às mudanças nas condições da vegetação/solo, onde ↑ indica aumento e ↓ indica diminuição.

| Alterações nas condições da vegetação/solo | $\sigma^0$ | $\rho_{Red}$ | $\rho_{NIR}$ |
|--|------------|--------------|--------------|
| Aumento na rugosidade do alvo              | ↑          | ↓            | ↓            |
| Diminuição da biomassa da vegetação        | ↑          | ↑            | ↓            |
| Aumento no conteúdo de umidade do solo     | ↑          | ↓            | ↓            |

$\sigma^0$  é retroespalhamento SAR,  $\rho_{Red}$  e  $\rho_{NIR}$  são a reflectância de superfície na região do vermelho e infravermelho próximo.

Fonte: Adaptado de Moran *et al.* (2002).

À medida que a rugosidade da superfície aumenta, o  $\sigma^0$  aumenta devido ao aumento do espalhamento SAR, enquanto  $\rho_{Red}$  e  $\rho_{NIR}$  diminuem devido ao aumento de sombras na superfície. Conforme a biomassa da vegetação diminui, normalmente tem-se o aumento do retroespalhamento ( $\sigma^0$ ) e um aumento na  $\rho_{Red}$  devido a diminuição da clorofila foliar e a  $\rho_{NIR}$  diminui devido a diminuição do espalhamento foliar. Além disso, conforme aumenta a umidade da superfície do solo, o  $\sigma^0$  aumenta devido a mudança na constante dielétrica do solo e,  $\rho_{Red}$  e  $\rho_{NIR}$  diminuem devido à absorção de água (MORAN *et al.*, 2002). Outra análise comparativa entre dados ópticos e SAR com base no estudo da vegetação é apresentado no Quadro 1.


**Quadro 1** - Comparação entre dados ópticos e SAR no estudo da vegetação.

| Aplicação                              | Óptico  | SAR  |
|--|---|--|
| Vegetação em geral                     | Proxis para parâmetros biofísicos e bioquímicos avaliados a partir dos pigmentos foliares e estrutura foliar.   | Proxis para teor de umidade e estrutura do dossel.   |
| Penetrabilidade no dossel da vegetação | Não há penetrabilidade nos alvos  | Há penetrabilidade no dossel da vegetação  |
| Agricultura                            | <ul style="list-style-type: none"> <li>▪ Detecção de pragas e doenças.</li> <li>▪ Mudanças na fenologia podem ser determinados a partir da banda do infravermelho próximo.</li> <li>▪ Monitoramento do desenvolvimento da cultura e estimativa de produção</li> </ul> | <ul style="list-style-type: none"> <li>▪ Detecção do conteúdo de umidade da planta e características do solo, as quais podem apoiar a detecção de doenças.</li> <li>▪ Auxilia no monitoramento do desenvolvimento da cultura.</li> </ul> |

Fonte: Adaptado de Agrawal e Khairnar (2019).

O mecanismo de interação entre os sinais SAR e o dossel da vegetação considera três componentes: espalhamento superficial atenuado pelo dossel da vegetação, espalhamento múltiplo (volumétrico e superficial) e retroespalhamento atenuado pelo solo (Figura 12) (BOUVET; LE TOAN; NGUYEN LAM-DAO, 2009).

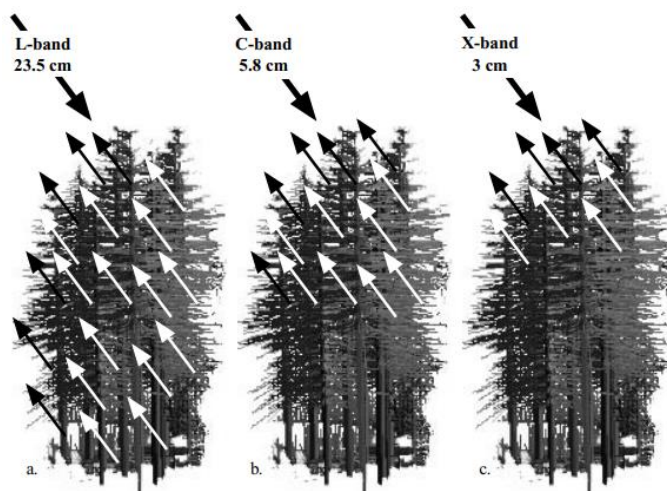
**Figura 12** - Interação do sinal retroespalhado com a vegetação quando ocorre: (a) espalhamento superficial atenuado pelo dossel da vegetação, (b) espalhamento múltiplo e (c) retroespalhamento atenuado pelo solo.



Fonte: Elaborado pelo autor.

As bandas SAR C (5,8 cm) e X (3 cm) são mencionadas por Chakraborty *et al.* (2005) como adequadas para recuperar os parâmetros biofísicos do dossel da vegetação, uma vez que as imagens produzidas a partir dos comprimentos de onda dessas bandas interagem principalmente com a parte superior do dossel da vegetação (Figura 13). Logo, quanto maior for a penetração da radiação no interior do dossel, maior será a quantidade de informações sobre troncos e galhos detectada pelo sinal retroespalhado. Por outro lado, quanto menor for a penetração da radiação no dossel, maior será a contribuição das folhas e galhos no total de informação retroespalhada que o sensor registrará.

**Figura 13** - Resposta teórica da vegetação à energia de micro-ondas das bandas L, C e X.



Fonte: Jensen (2014).

### 2.2.3 Sensoriamento Remoto na Agricultura

O sensoriamento remoto na agricultura tem por objetivo auxiliar no monitoramento de culturas agrícolas, estresse hídrico, propriedades do solo, irrigação e uso racional de produtos fitossanitários.

---

Diante disso, diferentes sensores podem fornecer informações sobre diversas características da cultura agrícola. Os sensores multiespectrais, por exemplo, que operam na região do SWIR permitem adquirir informações sobre a umidade de plantas e detecção de patógenos. Na região do infravermelho termal, é possível estimar a temperatura do dossel da cultura, enquanto os sistemas SAR auxiliam em estudos sobre umidade do solo (HUANG *et al.*, 2018).

A detecção de patógenos em culturas agrícolas a partir do sensoriamento remoto orbital tem sido amplamente aplicada devido as imagens de satélite recobrirem grandes áreas, baixo custo e períodos de revisita relativamente curtos. Por outro lado, os sensores orbitais ópticos são muito sensíveis às condições climáticas e atmosféricas, além de permitirem o imageamento somente durante o dia (GAO *et al.*, 2020), tornando difícil atender as necessidades de monitoramento de pragas e doenças em áreas agrícolas. Dados SAR são efetivos e importantes para esse propósito, já que são pouco influenciados pelas condições climáticas, são sensíveis às estruturas geométricas e propriedades dielétricas dos alvos, e possuem capacidade de penetração nos alvos (LIU *et al.*, 2019).

### **2.2.3.1 Monitoramento de doenças e patógenos na cultura cafeeira**

Entre os principais desafios da produção cafeeira estão os patógenos que causam doenças ou parasitam as plantas, como nematoides (MARTINS; GALO; VIEIRA, 2017), ferrugem (CHEMURA *et al.*, 2018), broca do café e o bicho-mineiro (ZISKA *et al.*, 2018). Os métodos de monitoramento desses patógenos dependem de levantamentos de campo que, apesar de serem amplamente adotados e efetivos, são dispendiosos. Por sua vez, o sensoriamento remoto tem sido considerado uma ferramenta apropriada para mapear e monitorar a heterogeneidade de culturas agrícolas e tem sido útil para reduzir a aplicação de produtos fitossanitários (CHEMURA; MUTANGA; DUBE, 2017a).

No entanto, o uso de imagens orbitais para monitoramento agrícola pode não ser trivial, uma vez que os dados gerados são dependentes da resolução temporal, espectral e espacial de cada sensor. No que se refere a cultura cafeeira, as características espectrais da cultura são dependentes de fatores relacionados a densidade de plantas, sistema de cultivo, bem como idade da planta (NOGUEIRA MARTINS *et al.*, 2021). Além disso, características como ciclo fenológico bianual do cafeeiro e de seu plantio, geralmente, em relevos mais acidentados, dificultam não apenas o mapeamento e monitoramento das áreas de cultivo do café, mas principalmente a detecção das áreas infestadas por patógenos. Isso ocorre devido à similaridade no comportamento espectral do café com outras fisionomias de uso da terra e a forte influência de sombras e ângulos de iluminação, devido ao comportamento acidentado do relevo (CORDERO-SANCHO e SADER, 2007).

---

Em geral, patógenos causam redução do conteúdo de clorofila devido a necrose ou lesões cloróticas, as quais afetam a reflectância na região do visível e *red-edge* (FRANKE e MENZ, 2007). Além disso, a vegetação senescente tem sua resposta espectral alterada na região do visível e do NIR. Ou seja, plantas afetadas por alguma doença apresentam baixa reflectância na região do NIR e elevada reflectância na região do vermelho (FELDERHOF e GILLIESON, 2011). Em relação à estrutura do dossel, a infecção por patógenos altera a densidade do dossel e a área foliar, o que pode ser observado no NIR (FRANKE e MENZ, 2007).

Índices de vegetação são umas das maneiras de identificar plantas afetadas por nematoides (LEMES *et al.*, 2020). Índices espectrais podem indicar o vigor da vegetação, distinguindo a vegetação saudável da vegetação senescente (DO AMARAL *et al.*, 2019; XUE e SU, 2017). Os índices de vegetação normalmente utilizados para detectar anomalias em culturas agrícolas são NDVI e Razão Simples.

O mapeamento e detecção de doenças no cafeeiro a partir de sensoriamento remoto ainda é um desafio. Isso se deve em parte à complexidade e variedade dos sistemas de produção de café, mas também se deve ao fato do café ser cultivado principalmente em paisagens heterogêneas, e em topografias complexas (CORDERO-SANCHO e SADER, 2007; HUNT *et al.* 2020b). O cafeeiro também é espectralmente similar a outros tipos de cobertura da terra e, portanto, é comumente confundido em abordagens de classificação, com outras culturas e fisionomias do uso e cobertura da terra (SCHMITT-HARSH, 2013). Além disso, a assinatura espectral do cafeeiro muda com a idade e ao longo de seu ciclo fenológico, bem como durante surtos de ferrugem (ARIAS, 2007).

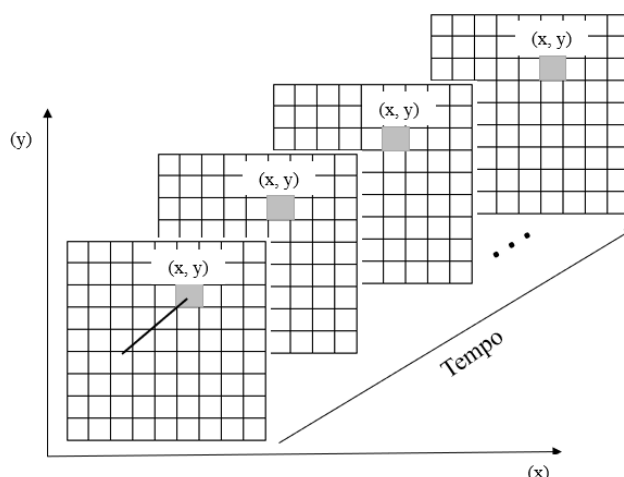
De acordo com Moran *et al.* (2002), devido a sinergia entre sinais ópticos e SAR em resposta às condições da vegetação, esses dados têm sido utilizados de forma combinada no monitoramento de culturas agrícolas. Dhau *et al.* (2019) mencionam que a aplicação bem-sucedida de imagens de sensoriamento remoto na detecção de doenças em culturas agrícolas também depende do algoritmo de classificação. Algoritmos baseados em aprendizagem de máquina podem ser eficazes na classificação de áreas cafeeiras e identificação da ocorrência de patógenos, uma vez que são tolerantes a ruídos e, podem ser robustos perante a resposta espectral complexa e variada do cafeeiro. Somando a isso, as técnicas de aprendizagem de máquina quando associadas a dados multissensores e multitemporais podem contribuir na identificação de padrões associados ao cultivo do cafeeiro e detecção de doenças.

### **2.2.3.2 Séries temporais de imagens de Sensoriamento Remoto**

Dado que uma imagem representa uma matriz, cada pixel de uma imagem possui um atributo em cada posição (x, y). Ao extrair o valor de um atributo de um determinado pixel, em uma sequência de  $n$  imagens ordenadas no tempo, gera-se uma série temporal para aquela célula

específica (JÖNSSON e EKLUNDH, 2004) (Figura 14). A partir da série temporal obtida para um pixel  $(x, y)$ , é possível realizar estudos sobre como se dá a evolução da informação representada por esse pixel ao decorrer do tempo. Sendo  $T = \{t: t_1 < t < t_2\} = \{1, 2, \dots, N\}$  um conjunto, uma série temporal pode ser denotada por  $\{Y(t): t \in T\}$  e ser do tipo contínua quando suas observações são coletadas continuamente no tempo e discreta se coletadas em tempos específicos (KOOPMANS, 1995).

**Figura 14** - Série temporal de imagens ordenadas no tempo destacando um pixel  $(x, y)$ .



Fonte: Adaptado de Jönsson e Eklundh (2004).

No caso das séries temporais de dados de sensoriamento remoto orbital, estas podem ser baseadas em uma série de dados em valores de reflectância de superfície ou de atributos derivados dos dados originais, tais como os índices de vegetação. As séries temporais podem contribuir inclusive no monitoramento de culturas agrícolas. Abordagens que utilizam séries temporais fornecem resultados acurados e robustos quando comparados com métodos tradicionais baseados em processamentos de uma única cena (JÖNSSON *et al.*, 2018). Isso porque os dados de uma única data não capturam padrões temporais de longo prazo e efeitos sazonais (SILVA-PEREZ *et al.*, 2021).

De modo especial, séries temporais de índices de vegetação permitem o monitoramento da fenologia e das variações intra-sazonais de áreas agrícolas (ARVOR *et al.*, 2011). No entanto, o monitoramento preciso de grandes áreas é dificultado por falta de dados com boa sinergia entre resolução espacial e temporal para composição de séries temporais regulares. Os Programa Copernicus da comunidade europeia dispõe de dois satélites ópticos (Sentinel-2A e Sentinel-2B) e dois satélites SAR (Sentinel-1A e Sentinel-1B), os quais são uma ótima oportunidade para monitoramento de culturas agrícolas, uma vez que permitem a geração de séries temporais mais densas e com melhor resolução espacial que missões de programas espaciais anteriores, como Landsat e MODIS (ZHAO *et al.*, 2020). Alguns trabalhos também sugerem que a utilização de séries temporais multissensor, tais como Sentinel-

---

1 e Sentinel-2, podem descrever melhor o ciclo de desenvolvimento de culturas agrícolas (VELOSO *et al.*, 2017).

Séries temporais derivadas de dados ópticos podem conter ruídos causados por nuvens, sombreamento da cena, bem como por efeitos atmosféricos. Diante disso, para monitoramento de culturas agrícolas é essencial a redução de ruídos, o que normalmente é realizado utilizando algoritmos de filtragem e suavização de séries temporais. Em relação a esse aspecto, estudos sugerem que o algoritmo Savitzky–Golay (SG) consegue preservar os padrões sazonais de séries temporais (CAO *et al.*, 2018; CHEN *et al.*, 2004, 2021a; RAHMAN; ROBSON; BRINKHOFF, 2022).

### 2.2.3.3 Modelos baseados em aprendizado de máquina na agricultura

A agricultura digital tem inovado ao utilizar abordagens e dados cada vez mais eficazes para impulsionar a produtividade agrícola e, ao mesmo tempo, minimizar seu impacto ambiental (LIAKOS *et al.*, 2018). Nesse sentido, a aprendizagem de máquina vem criando oportunidades para quantificar e compreender os processos empregados no setor agrícola, tais como detecção de estresse hídrico, patógenos e pragas causadas por insetos (LIAKOS *et al.*, 2018).


Uma das principais vantagens das técnicas de aprendizado de máquina é que elas são capazes de resolver de forma autônoma problemas de natureza não linear usando conjuntos de dados obtidos por diferentes fontes (CHLINGARYAN; SUKKARIEH; WHELAN, 2018), com base no pressuposto de que esses algoritmos são capazes de detectar e quantificar padrões em dados (BEHMANN *et al.*, 2015). Entre os algoritmos mais populares de aprendizado de máquina encontram-se o *k-Nearest Neighbors* (kNN), *Support Vector Machine* (SVM), Árvores de Decisão, *Random Forest* (RF), Redes Neurais Artificiais (RNAs), entre outros (LARY *et al.*, 2016). Cada um desses algoritmos apresenta características próprias, que os tornam apropriados para diferentes aplicações. Dentre esses, as RNAs são amplamente utilizadas em sensoriamento remoto para estimar parâmetros da vegetação, bem como para previsão de safras (FARIFTEH *et al.*, 2007; KAUL; HILL; WALTHALL, 2005).

Segundo GONZALEZ e WOODS, 2002, as RNAs são modelos matemáticos capazes de aprender e reconhecer padrões. A estrutura das RNAs foi, inicialmente, projetada para simular os processos neurais do cérebro humano. São compostas por várias unidades de processamento (neurônios ou nós) organizadas em camadas, sendo que o conhecimento é adquirido a partir de um processo de treinamento (aprendizado) e armazenado nas conexões entre as camadas (sinapses), que no caso são denominados como pesos.

A camada de entrada é onde os recursos são apresentados à rede, e a camada de saída é aquela onde os resultados são apresentados. Entre essas camadas, tem-se as camadas ocultas compostas por

neurônios, responsáveis pela soma ponderada dos sinais de entrada. O número de camadas ocultas em uma rede neural influencia na complexidade do modelo e a sua capacidade de aprender padrões mais abstratos ou complexos dos dados. Contudo, se muitas camadas forem usadas, a RNA pode resultar em *overfitting*, fazendo com que a rede memorize os dados de treinamento, resultando em previsões ruins (KAUL; HILL; WALTHALL, 2005). A arquitetura de rede neural com duas camadas escondidas é apresentada na Figura 15.

**Figura 15** - Modelo de rede neural com duas camadas escondidas.



Fonte: Adaptado de Gonzalez e Woods, (2002).

Na Figura 15, a entrada de um nó em qualquer camada é a soma ponderada da saída de um nó da camada anterior. Como exemplo, considere K como a camada anterior a camada J. A camada K fornece a entrada para o elemento de ativação de cada nó da camada J, denotada por  $I_j$  ( $j = 1, 2, \dots, N_j$ ) (Equação 4).

$$I_j = \sum_{k=1}^{N_K} w_{jk} O_k \quad (4)$$

Em que  $N_j$  é a quantidade de nós da camada J,  $N_k$  é a quantidade de nós da camada K, e  $w_{jk}$  são os pesos que modificam as saídas  $O_k$  dos nós na camada K antes de serem alimentados nos nós da camada J. As saídas da camada K são dadas por:

$$O_k = h_k(I_k) \quad (5)$$

Para  $k = 1, 2, \dots, N_K$ . Onde  $h_k(I_k)$  é denominado de função de ativação.

As funções de ativação são funções não lineares, as quais permitem a construção de funções complexas durante o aprendizado. Existem diversas funções de ativação, dentre elas têm-se a sigmoide,

tangente hiperbólica, a *Rectified Linear Unit* (ReLU) (GONZALEZ e WOODS, 2002). Considerando a função de ativação sigmoide (Equação 6), tem-se:

$$h_j(I_j) = \frac{1}{1 + e^{-(I_j + \theta_j)/\theta_0}} \quad (6)$$

e substituindo a Equação 4 na Equação 6, cada neurônio da rede passa a ser definido pela função sigmoide expressa na Equação 7.


$$h_j(I_j) = \frac{1}{1 + e^{-(\sum_{k=1}^{NK} w_{jk} O_k + \theta_j)/\theta_0}} \quad (7)$$

Em que  $\theta_j$  é um ganho adicional acrescido ao somatório dos coeficientes e  $\theta_0$  controla a forma da função sigmoide.

Para minimizar a função custo no treinamento de uma rede neural, é utilizado o algoritmo *backpropagation* com o método do gradiente descendente. Segundo Campbell e Wynne (2011), um dos objetivos desse algoritmo é o ajuste de pesos em cada uma das camadas da rede, além minimizar a soma do quadrado do erro entre a saída calculada por uma RNA multicamadas e a saída desejada. Mais informações sobre o algoritmo *backpropagation* podem ser obtidas em GONZALEZ e WOODS, (2002).

As redes neurais recorrentes (RNR) são uma extensão das redes neurais tradicionais, porém se diferem por lidarem com sequências temporais de dados (SCHUSTER e PALIWAL, 1997). Além disso, as redes *feedforward* recebem sinais apenas da camada de entrada, processa esses sinais e os passa à camada de saída. Por sua vez, as RNR recebem sinais tanto da camada de entrada quanto da camada oculta na iteração de tempo anterior. De modo geral, é como se a camada oculta de uma rede neural recorrente funcionasse como uma memória, ou seja, a cada período no tempo, a rede neural não só armazena no seu estado oculto informações dos dados observados naquele período no tempo, como também recupera informações do estado oculto anterior, armazenando informações relevantes do que aconteceu no passado. Na Figura 16, tem-se a representação de uma rede neural *feedforward* e uma rede neural recorrente.


**Figura 16** - Representação de uma rede neural: (a) *feedforward* e (b) rede neural recorrente.



Fonte: Adaptado de De Mulder; Bethard ; Moens (2015).

Ao contrário das redes neurais convencionais, na quais todas as entradas são independentes umas das outras, nas redes recorrentes todas as entradas estão relacionadas entre si. A Figura 17 ilustra o funcionamento de uma RNR.

**Figura 17** - Estrutura de uma RNR ao longo do tempo.



Fonte: Adaptado de Tyagi e Abraham (2023).

A entrada de uma RNR é uma sequência de dados  $\{x_1, x_2, \dots, x_t\}$ . O nó atualiza seu estado oculto  $h_t$ , dado seu estado anterior  $h_{t-1}$  e a entrada atual  $x_t$ , de acordo com a seguinte equação:

$$h_t = \sigma(W_{hx}x_t + W_{hh}h_{t-1} + b) \quad (8)$$

$h_t$  é a camada intermediária no tempo  $t$ ;  $b$  e  $\sigma$  são o *bias* e uma função de ativação não linear;  $W_{hx}$  é o peso entre o nó de entrada e o nó oculto recorrente;  $x_t$  é a entrada no instante  $t$ ;  $h_{t-1}$  é a camada intermediária no instante  $t - 1$ . A partir disso, a equação de saída da camada intermediária é dada por:

$$z_t = g_n(W_{hz}h_t + b_z) \quad (9)$$

sendo  $z_t$  o vetor de saída,  $W_{hz}$  a matriz de pesos para a camada de saída, e  $b_z$  o *bias*.

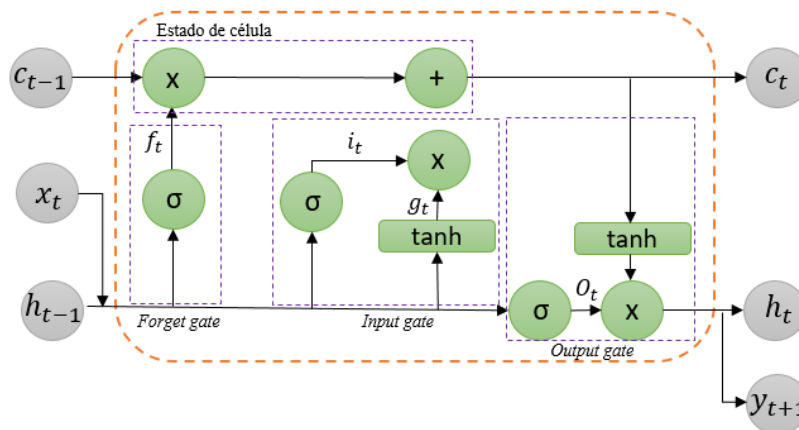
Como pode ser visto na Equação 9, a diferença fundamental entre a equação da RNR e a equação das redes neurais clássicas é a inserção da informação do estado oculto anterior ( $W_{hh}h_{t-1}$ ). Além disso, os parâmetros que fazem a transição da informação entre os estados ocultos de diferentes períodos são sempre os mesmos. Isso mostra que redes neurais recorrentes compartilham parâmetros

através do tempo.

Durante o treinamento de uma RNR, os gradientes podem se aproximar do infinito ou de zero à medida que o intervalo de tempo aumenta se  $|W_{hh}| < 1$  ou  $|W_{hh}| > 1$ . Isso levará aos problemas de desaparecimento (*vanishing*) e explosão (*exploding*) do gradiente, os quais ocorrem durante a retropropagação do erro em redes com múltiplas camadas. A explosão de gradiente ocorre quando grandes gradientes de erros se acumulam e resultam em enormes atualizações dos pesos. Por outro lado, devido ao aumento do número de camadas ou devido a retropropagação nas fases de treinamento, pode haver uma perda da informação do gradiente e, dessa forma, dificuldade de convergências dos valores de peso, ocasionando o problema de desaparecimento de gradiente (SALEHINEJAD *et al.*, 2018).

Para lidar com esses problemas, foram propostas as redes *Long Short Term Memory* (LSTM) para substituir o nó oculto recorrente por uma célula de memória. As redes LSTM são capazes de aprender dependências de longo prazo. Em uma rede LSTM, o estado interno consiste em um conjunto de sub-redes conectadas, chamadas de blocos de memória (Figura 18). Cada bloco é composto por quatro estruturas: *input gate* (porta de entrada,  $i_t$ ), *output gate* (porta de saída,  $o_t$ ), *forget gate* (porta de esquecimento,  $f_t$ ), e a principal delas que é a célula de memória ( $\tilde{C}_t$ ) (GRAVES, 2012a).

**Figura 18** - Estrutura de uma rede LSTM.



Fonte: Adaptado de Vyas *et al.* (2022).

A porta de esquecimento controla se as informações do estado anterior devem ser descartadas e o quanto de memória deve ser lembrada. A porta de entrada controla quais novas informações são adicionadas ao estado da célula a partir da entrada atual. Já a porta de saída decide o que retornar de memória e decide qual parte da célula atual chega à saída. De acordo com essas estruturas, a célula de memória e a saída são calculadas de acordo com as seguintes equações:

---


$$f_t = \sigma(W_{hf} \cdot h_{t-1} + W_{xf} \cdot x_t + b_f) \quad (10)$$

$$i_t = \sigma(W_{hi} \cdot h_{t-1} + W_{xi} \cdot x_t + b_i) \quad (11)$$

$$\tilde{C}_t = \tanh(W_{hc} \cdot h_{t-1} + W_{xc} \cdot x_t + b_c) \quad (12)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tilde{C}_t \quad (13)$$

$$o_t = \sigma(W_{ho} \cdot h_{t-1} + W_{xo} \cdot x_t + b_o) \quad (14)$$

$$h_t = o_t \circ \tanh(C_t) \quad (15)$$

$\sigma$  é a função logística sigmoide, ‘ $\cdot$ ’ é um operador de multiplicação de matrizes, ‘ $\circ$ ’ é um operador de produto escalar, e  $b_f$ ,  $b_i$ ,  $b_c$  bem como  $b_o$  são bias.  $W_{hi}$  é a matriz de porta de entrada oculta, e  $W_{xo}$  matriz de porta de entrada-saída.

## Capítulo 3

### ÁREA DE ESTUDO E ESCOPO METODOLÓGICO

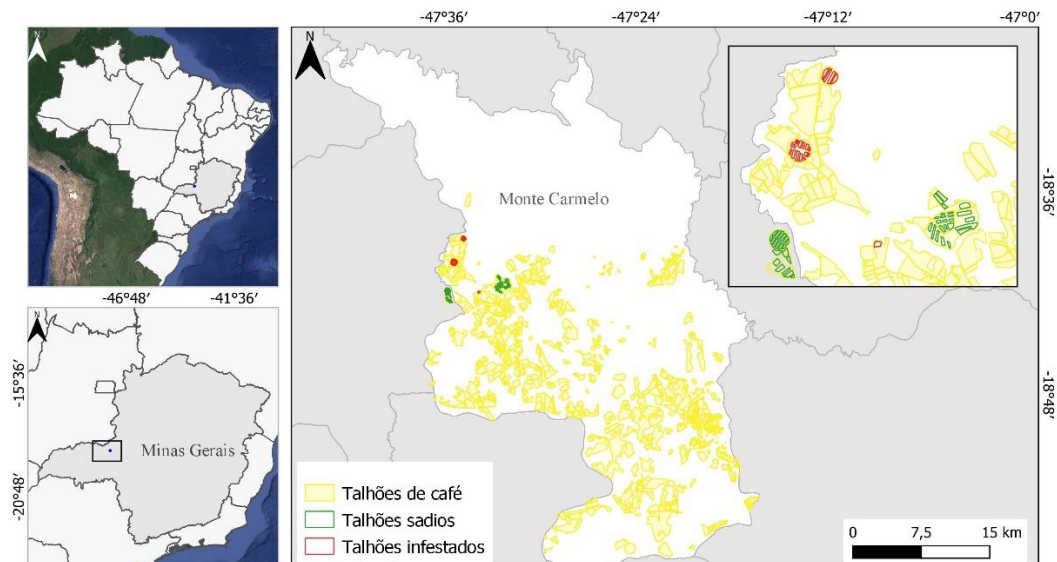
Nesse capítulo apresenta-se uma breve descrição da área de estudo (Seção 3.1.1), os dados de referência utilizados nos experimentos realizados (Seção 3.1.2) e os conjuntos de dados espectrais e SAR explorados (Seção 3.1.3). Além disso, a Seção 3.2 mostra o conjunto de procedimentos aplicados para pré-processamento dos dados.

### 3.1 Material

#### 3.1.1 Área de estudo

A área de estudo está inserida no município de Monte Carmelo, Minas Gerais, Brasil ( $18^{\circ}43'50,56''$  S,  $47^{\circ}29'30''$  O) (Figura 19). O município de Monte Carmelo está localizado na região do Cerrado Mineiro, umas das principais regiões produtoras de café do Brasil, responsável por aproximadamente 25,4% da produção mineira e mais de 12,7% da produção nacional (DE ALMEIDA e TARABAL, 2019).

**Figura 19** - Área de estudo e distribuição de talhões de café. Polígonos em amarelo representam a localização de talhões de café. No destaque: polígonos em verde representam talhões saudios e os polígonos em vermelho os talhões infestados.

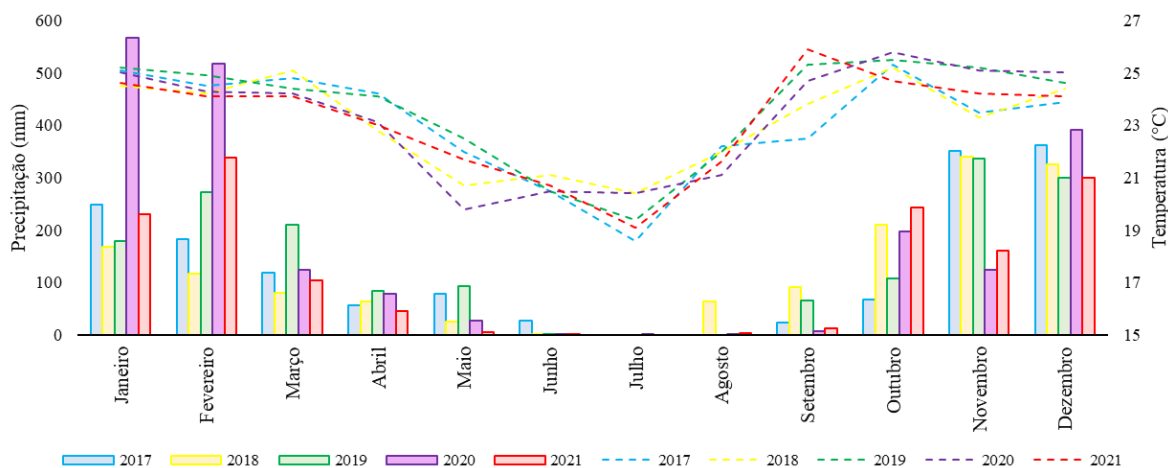


Fonte: Elaborado pelo autor.

A região do Cerrado Mineiro tem clima favorável ao desenvolvimento da cultura cafeeira. Com clima predominantemente ameno e estações bem definidas, a temperatura média varia de  $18^{\circ}\text{C}$  a  $22^{\circ}\text{C}$  (Figura 20). A região é caracterizada por verão quente e chuvoso com índice pluviométrico em torno dos 1.600 mm anuais e predominância de relevo plano a

ondulado, com altitudes variando entre 850 a 1.250 metros (DE ALMEIDA e TARABAL, 2019).

**Figura 20** - Representação gráfica de variáveis climatológicas registradas mensalmente, no município de Monte Carmelo entre os anos de 2017 e 2021. As barras representam a precipitação acumulada no mês (mm) e as linhas pontilhadas representam a temperatura média mensal (°C).



Fonte: Adaptado de <https://sismet.cooxupe.com.br>.

A seleção da área de estudo levou em consideração a importância da região na produção nacional de café, reconhecida por obter a primeira Indicação de Procedência e Denominação de Origem para café no país. Diante desse cenário, esta pesquisa contou com a parceria da Universidade Federal de Uberlândia (UFU) - Campus Monte Carmelo, a qual vem se destacando na região do Cerrado Mineiro com pesquisas voltadas ao setor agrícola, entre as quais se destacam aquelas com foco no mapeamento e monitoramento de pragas e doenças em cultivares de cafeeiro.

### 3.1.2 Dados de referência

Nesta pesquisa, são considerados como dados de referência talhões de cultivo de café nos quais esteja certificada a ocorrência de nematoides e talhões considerados sadios. Os talhões de referência foram fornecidos pelo Instituto de Ciências Agrárias, da Universidade Federal de Uberlândia (UFU) – Campus Monte Carmelo, na forma de arquivos vetoriais. Para seleção dos talhões de referência, priorizou-se áreas em que estejam certificadas a ocorrência de nematoides seja por meio de laudos de análises laboratoriais ou por meio de trabalhos publicados em periódicos. Outro importante fator considerado na seleção das áreas de referência é que o cafezal não tenha sido suprimido durante o período considerado dessa pesquisa (2017 – 2021). A Figura 21 mostra o exemplo de uma área infestada por nematoides, onde o cafezal foi removido entre os anos de 2018 e 2020, o que inviabilizou a análise temporal desse talhão.

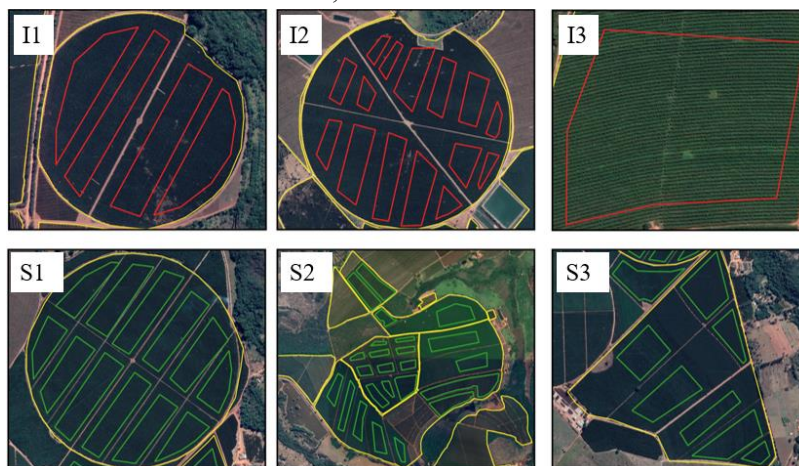
**Figura 21** - Área em que o cafezal foi removido entre os anos de 2018 e 2020.



Fonte: Google Earth (2023).

Diante dos fatores mencionados anteriormente, foram selecionadas 6 áreas produtoras de café, as quais estão indicadas na Figura 22 como talhões infestados por nematoides (I1, I2 e I3) e talhões saudáveis (S1, S2 e S3). De modo a evitar a inclusão de solo exposto dos carregadores entre talhões, bem como o efeito de borda, os polígonos com a delimitação dos talhões de cafeeiros foram subamostrados nos polígonos representados em verde (áreas saudáveis) e vermelho (áreas infestadas por nematoides), para posterior extração dos atributos (Figura 22). Desse modo, a máscara contendo os polígonos de referência inseridos nos talhões saudáveis e infestados foi aplicada a cada cena que dos atributos (ópticos e SAR) selecionados para construção das séries temporais. Esse delineamento amostral foi utilizado nas fases de estudo de atributos e nos experimentos para detecção de nematoides. A quantidade de pixels presentes em cada área de referência após subamostragem é apresentada na Tabela 6.

**Figura 22** - Delineamento amostral usado na definição das áreas de referência para geração dos perfis temporais. Polígonos em vermelho, inseridos nos talhões I1, I2 e I3 indicam áreas infestadas, enquanto os polígonos em verde dos talhões S1, S2 e S3 são talhões com cafeeiros saudáveis.



Fonte: Elaborado pelo autor.


**Tabela 6** – Dimensão e número de pixels de cada área de referência sadia (S1, S2 e S3) e infestada (I1, I2 e I3). A informação de Área (ha) refere-se ao tamanho do talhão de referência preliminarmente a subamostragem dos polígonos para remoção de solo exposto.

| Área de referência | Área (ha) | Pixels |
|--------------------|-----------|--------|
| I1                 | 30,05     | 1384   |
| I2                 | 54,03     | 1847   |
| I3                 | 4,02      | 397    |
| S1                 | 39,91     | 2000   |
| S2                 | 213,03    | 6601   |
| S3                 | 59,60     | 2347   |

Fonte: Elaborado pelo autor.

Em dezembro de 2019, uma visita em campo foi realizada com o objetivo de identificar os efeitos da infestação por nematoides no cafeeiro. Na mencionada visita, foi possível observar que os principais sintomas incluem queda e amarelecimento das folhas, além do amadurecimento prematuro dos frutos (Figura 23). Além disso, análises nematológicas indicaram que a densidade populacional de nematoides totais em uma das áreas visitadas (talhão I3, Figura 22) estava entre 1300 e 1500 indivíduos/150 cm<sup>3</sup> de solo (PEREIRA *et al.*, 2022).

**Figura 23** - Exemplos de cafeeiros infestados por nematoides no município de Monte Carmelo – MG.



Fonte: Elaborado pelo autor.

### 3.1.3 Dados ópticos e SAR Sentinel

Os dados utilizados consistiram em imagens ópticas Sentinel-2 (Tabela 7) e SAR Sentinel-1 (Tabela 8) mensais, entre os anos de 2017 e 2021, obtidos gratuitamente pelo programa Copernicus, da Agência Espacial Europeia (*European Space Agency* - ESA) (<https://scihub.copernicus.eu>). A utilização dos dados da missão Sentinel é pautada pela boa sinergia entre resolução espacial, espectral e temporal, fornecendo novas oportunidades para classificação e monitoramento de culturas agrícolas, quando comparado com outros sensores como Landsat e MODIS.

Os produtos Sentinel-2 são fornecidos com resolução radiométrica de 12 bits, largura de faixa de imageamento de 290 km, 5 dias de revisita e 13 bandas espectrais adquiridas nas regiões do visível, infravermelho próximo (NIR), e infravermelho de ondas curtas (SWIR), em três resoluções espaciais (10, 20 e 60 m).

**Tabela 7** - Configuração espectral e resolução espacial de imagens Sentinel-2.

| <b>Bandas</b>           | <b>Resolução Espacial (m)</b> | <b>Comprimento de onda central (nm)</b> |
|-------------------------|-------------------------------|---|
| Azul (B2)               | 10                            | 492,4                                   |
| Verde (B3)              |                               | 559,8                                   |
| Vermelho (B4)           |                               | 664,6                                   |
| NIR (B8)                |                               | 832,8                                   |
| <i>Red-edge</i> 1 (B5)  | 20                            | 704,1                                   |
| <i>Red-edge</i> 2 (B6)  |                               | 740,5                                   |
| <i>Red-edge</i> 3 (B7)  |                               | 782,8                                   |
| <i>Red-edge</i> 4 (B8A) |                               | 864,7                                   |
| SWIR 1 (B11)            |                               | 1613,7                                  |
| SWIR 2 (B12)            |                               | 2202,4                                  |
| Aerossol (B1)           | 60                            | 442,7                                   |
| Vapor d'água (B9)       |                               | 945,1                                   |
| Cirrus (B10)            |                               | 1373,5                                  |

Fonte: *European Space Agency* [s.d.].

O satélite Sentinel-1A possui embarcado uma antena SAR a qual opera na banda C adquirindo imagens em duas polarizações, VV e VH. Os dados podem ser adquiridos em quatro modos de aquisição, sendo eles: *Stripmap* (SM), *Interferometric Wide swath* (IW), *Extra Wide swath* (EW) e *Wave* (WV). Além disso, os dados são distribuídos na forma dos produtos *Raw Level-0* (dados brutos), *Single Look Complex* (SLC – amplitude e fase), *Ground Range Detected* (GRD - amplitude) e *Level-2 Ocean* (OCN). Nesta pesquisa, os dados SAR utilizados correspondem aos dados GRD no modo de aquisição IW (Tabela 8). O modo IW é o principal modo de aquisição de dados terrestres, além de ser o único modo recomendado para estudos em agricultura (EUROPEAN SPACE AGENCY, [s.d.]).

**Tabela 8** – Especificação de cada parâmetro das imagens Sentinel-1.

| <b>Sensor</b>        | <b>Sentinel-1</b> |
|----------------------|-------------------|
| Órbita               | Ascendente        |
| Sensor               | C-SAR (5.405 GHz) |
| Modo de Imageamento  | IW                |
| Resolução Espacial   | 20 X 22 m         |
| Tamanho do pixel     | 10 x 10 m         |
| Ângulo de incidência | 29.1° - 46°       |
| Polarizações         | VV, VH            |

**Tabela 8** – Especificação de cada parâmetro das imagens Sentinel-1.

| Sensor              | Sentinel-1 |
|---------------------|------------|
| Resolução Temporal  | 6 dias     |
| Comprimento de onda | 5.6 cm     |
| Produto             | GRD        |

Fonte: *European Space Agency* [s.d.].

O produto Sentinel-1 GRD apresenta informação de amplitude e resolução espacial de 20 x 22 m, reamostrada para pixels de 10 x 10 m. A resolução espacial, no contexto de dados SAR, é definida como a distância mínima na qual o radar pode discriminar entre dois alvos que emitem ecos aproximadamente iguais. Normalmente, em produtos GRD, o tamanho do pixel corresponde à aproximadamente metade da resolução espacial das imagens. De acordo com Bourbigot (2016), para que todo o conteúdo de informação da imagem seja retido, o espaçamento de pixels deve atender ao critério de Nyquist. Segundo o teorema de amostragem de Nyquist, sempre existe perda em um sinal amostrado, contudo esse sinal não será afetado na discretização, se esta ocorrer com uma frequência de amostragem duas vezes maior que a frequência do sinal (NYQUIST, 1928). Desse modo, para atender a esse critério a taxa de amostragem espacial (tamanho do pixel) dos dados SAR deve ser menor que a resolução espacial.

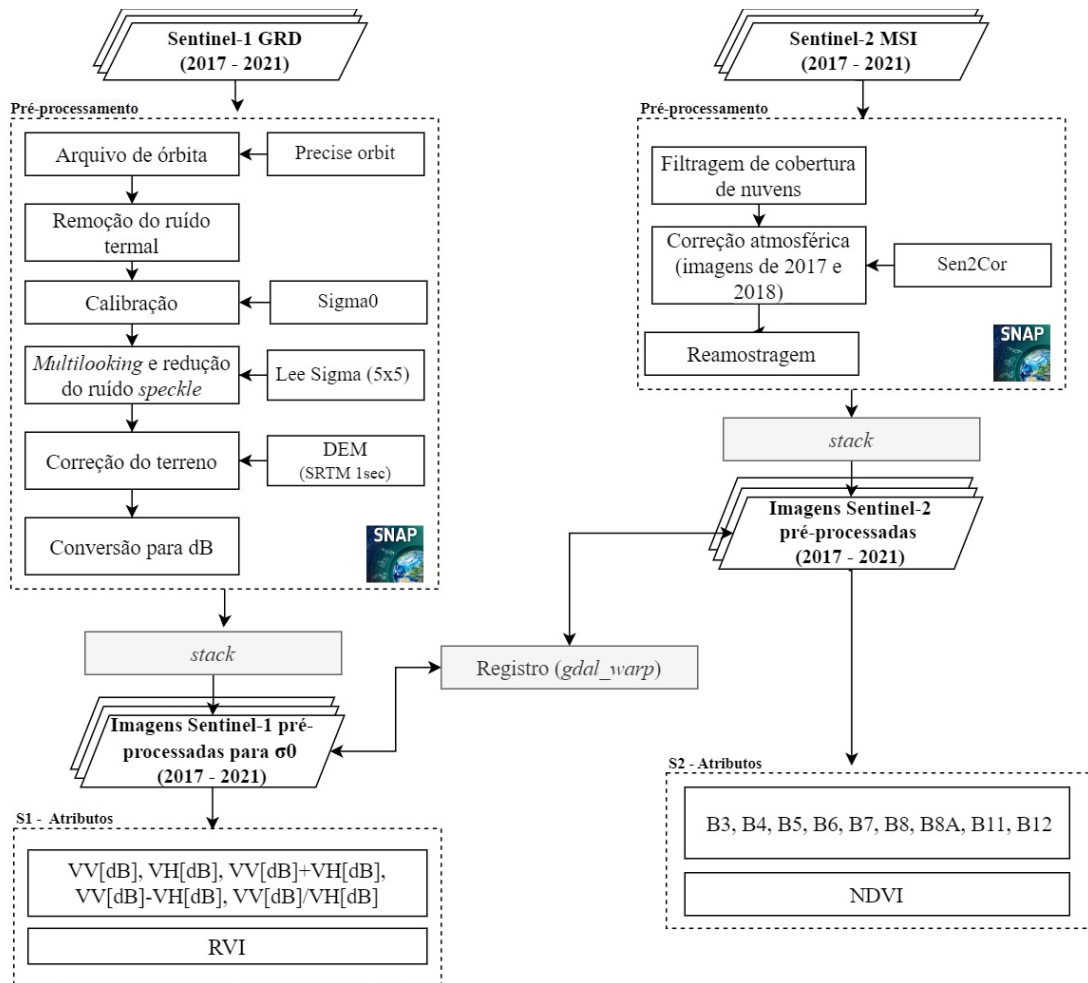
As imagens Sentinel-1 são tomadas com os ângulos de incidência que variam entre 29,1° e 46°, o que a torna adequada para monitoramento de culturas agrícolas (VELOSO *et al.*, 2017). Ângulos de incidência < 30° reduzem a atenuação da vegetação e maximizam a contribuição do espalhamento do solo, o que é mais útil para a medição da umidade do solo. Além disso, ângulos de incidência entre 35° e 40° maximizam a contribuição da vegetação.

## 3.2 Abordagem metodológica

### 3.2.1 Pré-processamentos aplicados aos dados Sentinel

Foram incluídos nesta etapa todos os processamentos aplicados aos dados SAR e ópticos até a geração dos atributos avaliados temporalmente. Para os dados SAR, esses processamentos culminaram com a geração das imagens  $\sigma^0VV$  e  $\sigma^0VH$  em decibéis, as combinações das polarizações e índices polarimétricos, enquanto para dados ópticos foram geradas as bandas espectrais em reflectância de superfície e o NDVI. O fluxograma das etapas mencionadas anteriormente é apresentado na Figura 24.


**Figura 24** - Fluxograma geral das etapas de pré-processamento dos dados Sentinel-1 e Sentinel-2.



Fonte: Elaborado pelo autor.

O pré-processamento das imagens Sentinel-1 e Sentinel-2 foi realizado por meio do *software* SNAP (*Sentinel Application Platform*), disponível no *site* da ESA. Para os dados ópticos, o pré-processamento consistiu basicamente em filtragem da cobertura de nuvens, correção atmosférica e reamostragem. O conjunto de dados de imagens ópticas foi filtrado para que apenas cenas com até 10% de cobertura de nuvens fossem incluídas no conjunto de dados. Após essa etapa, 10 imagens extrapolaram a cobertura de nuvens admissível. Essas imagens se referem aos meses de janeiro, maio e outubro de 2017, janeiro e novembro de 2018, março de 2019, janeiro a março de 2020, e dezembro de 2021 (Figura 25). Ao final dessas etapas, o conjunto de dados foi composto por 60 imagens Sentinel-1 e 50 imagens Sentinel-2 (Quadro 2).

**Figura 25** - Representação das datas das imagens Sentinel-1 e Sentinel-2. Em vermelho é representado as datas das imagens ópticas Sentinel-1 e em azul as datas das imagens Sentinel-2.



Fonte: Elaborado pelo autor.

**Quadro 2** - Datas das imagens Sentinel-1 e Sentinel-2 que compuseram o conjunto de dados. Os retângulos em amarelo representam ausência imagem no mês considerado.

| Sentinel 1 |            |            | Sentinel 2 |            |            |
|------------|------------|------------|------------|------------|------------|
| 13/01/2017 | 11/10/2018 | 20/07/2020 |            | 02/10/2018 | 18/07/2020 |
| 18/02/2017 | 16/11/2018 | 25/08/2020 | 24/02/2017 |            | 12/08/2020 |
| 14/03/2017 | 22/12/2018 | 18/09/2020 | 16/03/2017 | 21/12/2018 | 16/09/2020 |
| 19/04/2017 | 15/01/2019 | 12/10/2020 | 05/04/2017 | 25/01/2019 | 06/10/2020 |
| 13/05/2017 | 20/02/2019 | 17/11/2020 |            | 24/02/2019 | 05/11/2020 |
| 18/06/2017 | 16/03/2019 | 23/12/2020 | 04/06/2017 |            | 30/12/2020 |
| 12/07/2017 | 21/04/2019 | 16/01/2021 | 09/07/2017 | 30/04/2019 | 19/01/2021 |
| 17/08/2017 | 15/05/2019 | 21/02/2021 | 03/08/2017 | 30/05/2019 | 03/02/2021 |
| 10/09/2017 | 20/06/2019 | 27/03/2021 | 12/09/2017 | 19/06/2019 | 25/03/2021 |
| 16/10/2017 | 26/07/2019 | 22/04/2021 |            | 19/07/2019 | 24/04/2021 |
| 21/11/2017 | 19/08/2019 | 16/05/2021 | 16/11/2017 | 13/08/2019 | 04/05/2021 |
| 15/12/2017 | 12/09/2019 | 21/06/2021 | 21/12/2017 | 17/09/2019 | 18/06/2021 |
| 20/01/2018 | 18/10/2019 | 27/07/2021 |            | 17/10/2019 | 13/07/2021 |
| 21/02/2018 | 11/11/2019 | 20/08/2021 | 14/02/2018 | 11/11/2019 | 27/08/2021 |
| 21/03/2018 | 17/12/2019 | 13/09/2021 | 16/03/2018 | 16/12/2019 | 06/09/2021 |
| 14/04/2018 | 22/01/2020 | 07/10/2021 | 30/04/2018 |            | 06/10/2021 |
| 20/05/2018 | 27/02/2020 | 12/11/2021 | 05/05/2018 |            | 25/11/2021 |
| 25/06/2018 | 22/03/2020 | 18/12/2021 | 14/06/2018 |            |            |
| 19/07/2018 | 15/04/2020 |            | 19/07/2018 | 29/04/2020 |            |
| 12/08/2018 | 21/05/2020 |            | 13/08/2018 | 04/05/2020 |            |
| 17/09/2018 | 14/06/2020 |            | 12/09/2018 | 13/06/2020 |            |

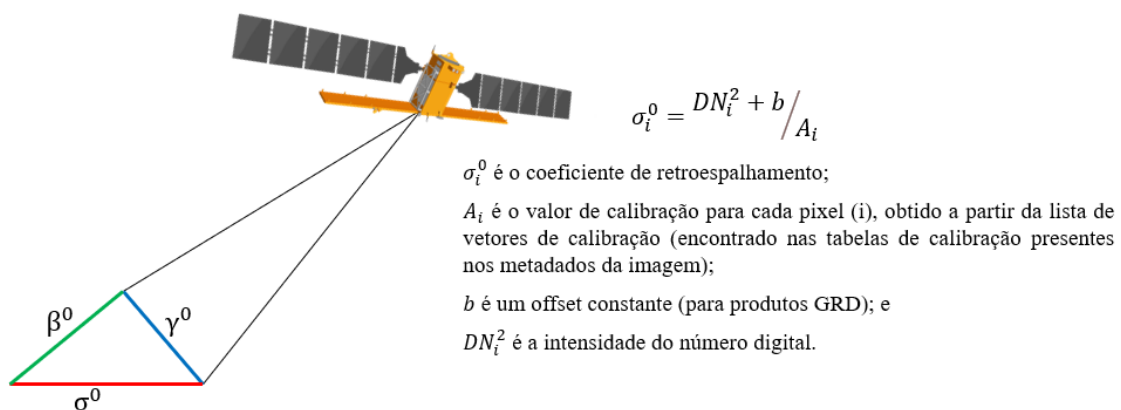
Fonte: Elaborado pelo autor.

As imagens Sentinel-2 entre 2017 e 2018 foram processadas do nível 1C para nível 2A (reflectância de superfície), utilizando o algoritmo Sen2Cor (LOUIS *et al.*, 2016). As imagens de 2019, 2020 e 2021 foram adquiridos já em reflectância de superfície. Posteriormente, as bandas da região do *red-edge* (B5, B6, B7 e B8A) e SWIR (B11 e B12) foram reamostradas, a partir do método do vizinho mais próximo, para 10 m. Nos experimentos realizados foi excluída a banda do azul (B2), uma vez que esta é a banda mais sensível às condições atmosféricas. Além disso, foi gerado o atributo NDVI (Índice de Vegetação por Diferença Normalizada) a partir dos valores de reflectância de superfície registrados nas bandas NIR (B8) e Vermelho (B4).

O pré-processamento das imagens Sentinel-1 GRD foi realizado de modo a converter a amplitude do sinal retroespalhado em valores de coeficiente de retroespalhamento ( $\sigma^0$ ). O processamento em *batch* foi adotado, pois permite o processamento de grandes conjuntos de dados de forma automatizada. A aquisição do arquivo de órbita e a remoção do ruído termal iniciaram o pré-processamento das imagens Sentinel-1. A aplicação de arquivo de órbita tem por objetivo atualizar o arquivo de órbita oriundo nos metadados do produto SAR. Esse procedimento é necessário porque o arquivo disponibilizado inicialmente não é preciso e, diante disso, pode ser refinado com um arquivo de órbita precisa. A redução do ruído termal é necessária para normalização do sinal retroespalhado em toda a imagem SAR, sendo uma importante etapa para uma calibração radiométrica precisa (MASCOLO; LOPEZ-SANCHEZ; CLOUDE, 2022). Nos dados Sentinel-1, o ruído termal pode ser oriundo de duas fontes. A primeira está relacionada ao padrão da antena e, portanto, varia na direção do alcance. A segunda é devido ao *scalping noise*, o qual varia ao longo da direção azimutal (MASCOLO; LOPEZ-SANCHEZ; CLOUDE, 2022).

Posteriormente, as imagens foram calibradas, a partir de um processo que converte os valores digitais (amplitude do sinal retroespalhado) em valores de retroespalhamento calibrados radiometricamente ( $\sigma^0$ VV e  $\sigma^0$ VH). Os dados Sentinel-1 podem ser calibrados de três modos, *sigma nought* ( $\sigma^0$ ), *beta nought* ( $\beta^0$ ) e *Gamma* ( $\gamma^0$ ) (Figura 26). Neste trabalho, as imagens SAR foram calibradas em  $\sigma^0$ , o qual está relacionado com a energia retornada para a antena por unidade de área a partir do solo.

**Figura 26** - Ilustração das calibrações *sigma nought* ( $\sigma^0$ ), *beta nought* ( $\beta^0$ ) e *gamma* ( $\gamma^0$ ).



Fonte: Adaptado de Gumelar; Dawei ; Rizkiyanto (2017).

O processamento *multilooking* e a redução do *speckle* são usados para reduzir ruídos nas imagens SAR (FILIPPONI, 2019). Para o processamento das imagens adquiridas em diferentes datas, foi aplicado o filtro Lee multitemporal com tamanho de janela de  $5 \times 5$  pixels

(QUEGAN; JIONG JIONG YU, 2001). Considerando uma sequência de  $N$  imagens multitemporais registradas, com intensidade na posição  $(x, y)$  na  $k$ -ésima imagem denotada por  $I_k(x, y)$ , as imagens filtradas temporalmente são dadas por:

$$J_k(x, y) = \frac{E[I_k]}{N} \sum_{i=1}^N \frac{I_i(x, y)}{E[I_i]} \quad (16)$$

Para  $k = 1, \dots, N$ , onde  $E[I]$  é a média local dos pixels em uma janela centrada em  $(x, y)$  na imagem  $I$ .

Devido às variações topográficas de uma cena e à inclinação do sensor do satélite, as distâncias podem ser distorcidas nas imagens SAR. Assim, estas imagens podem ser geocodificadas usando os dados *Shuttle Radar Topography Mission* (SRTM) para corrigir deformações topográficas. Finalmente, todas as imagens foram convertidas da escala linear para decibel (dB) usando a seguinte equação:

$$\sigma^0(dB) = 10 \times \log_{10}(\sigma^0) \quad (17)$$

### 3.2.2 Registro das imagens Sentinel e geração de atributos espectrais e polarimétricos

Com o intuito de garantir o alinhamento das imagens ópticas e SAR, foi utilizada a função *warp*, disponível na biblioteca *Geospatial Data Abstraction Library* (GDAL) em *python*. Para aplicação dessa função as imagens Sentinel-1 foram utilizadas como referência para alinhar as imagens Sentinel-2. Garantido o alinhamento das imagens ópticas e SAR, procedeu-se para a definição dos atributos a serem utilizados nos experimentos desta pesquisa. A Tabela 9 lista os atributos definidos a partir das imagens ópticas e SAR. Dez bandas espectrais Sentinel-2 e o índice NDVI foram considerados como os atributos ópticos, já para os dados Sentinel-1, são propostos 6 atributos que podem auxiliar na detecção de nematoides na cultura cafeeira.

**Tabela 9** - Resumo dos atributos obtidos para dados Sentinel-1 e Sentinel-2.  $\rho$  é a reflectância de superfície em uma banda espectral específica e  $\sigma^0$  é o coeficiente de retroespalhamento na polarização VV ou VH. NDVI é o Índice de Vegetação por Diferença Normalizada.

|                          | <b>Atributos</b>                                      | <b>Abreviação</b>   |
|--------------------------|---|---|
| <b>Atributos Ópticos</b> | $\rho_{verde}$  | B3  |
|                          | $\rho_{vermelho}$                                     | B4  |
|                          | $\rho_{NIR}$  | B8  |
|                          | $\rho_{Red\ Edge\ 1}$                                 | B5  |
|                          | $\rho_{Red\ Edge\ 2}$                                 | B6  |
|                          | $\rho_{Red\ Edge\ 3}$                                 | B7  |
|                          | $\rho_{Red\ Edge\ 4}$                                 | B8A   |
|                          | $\rho_{SWIR1}$  | B11   |
|                          | $\rho_{SWIR2}$  | B12   |
|                          |   | $\rho_{NIR} - \rho_{vermelho} / \rho_{NIR} + \rho_{vermelho}$ |
| <b>Atributos SAR</b>     | Retroespalhamento VV                                  | $\sigma^0_{VV}$   |
|                          | Retroespalhamento VH                                  | $\sigma^0_{VH}$   |
|                          | Soma das polarizações VV e VH                         | sumVVVH   |
|                          | Subtração das polarizações VV e VH                    | subVVVH   |
|                          | Razão entre as polarizações VV e VH                   | ratioVVVH   |
|                          | $(4 \sigma^0_{VH} / (\sigma^0_{VV} + \sigma^0_{VH}))$ | RVI   |

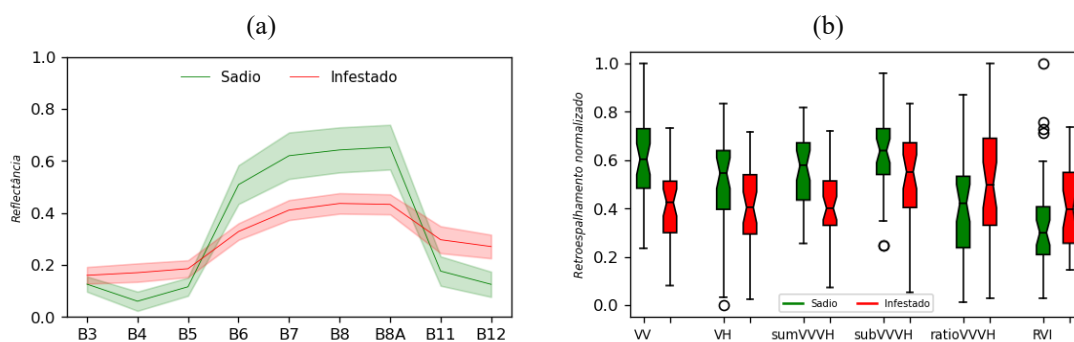
Fonte: Elaborado pelo autor.

Com relação aos atributos polarimétricos, o índice RVI ( $4 \text{ VH} / (\text{VV} + \text{VH})$ ) é uma adaptação do índice RVI proposto por Charbonneau; Trudel; Fernandes (2005) para dados SAR totalmente polarizados. A adaptação proposta por Nasirzadehdizaji *et al.* (2019) é facilmente aplicada aos dados Sentinel-1, uma vez que assume que  $\text{HH} \approx \text{VV}$  e  $\text{HV} \approx \text{VH}$ . Além disso, deve-se notar que o índice é calculado com base no coeficiente de retroespalhamento em medidas lineares. É relatado na literatura que esse índice é um bom atributo para estudos da vegetação, uma vez que ele pode reduzir o efeito *double-bounce* o qual é causado pelo espalhamento da vegetação-solo (VELOSO *et al.*, 2017).

### 3.2.3 Potencial de dados Sentinel na detecção de nematoides

Com o intuito de investigar a possibilidade de discriminação de nematoides em talhões de cultivo de café, inicialmente, foram analisadas as assinaturas espectrais do cafeeiro sadio e do cafeeiro infestado por nematoides para os atributos extraídos das imagens Sentinel-1 e Sentinel-2 (Figura 27).

**Figura 27** - (a) Reflectância média para as bandas espectrais do Sentinel-2 e valores normalizados dos atributos Sentinel-1 de talhões sadios e infestados por nematoides. Na Figura (a) a largura da faixa refere-se ao desvio padrão dos valores de reflectância para cada banda.



Fonte: Elaborado pelo autor.

O cafeeiro sadio apresentou fator de refletância menor que o café infestado na região do visível (B3 e B4), *red-edge* 1 (B5) e do SWIR (B11 e B12). A vegetação saudável na região do infravermelho próximo tem baixa absorção, consequentemente atingindo altos valores de reflectância. Clorofila a e b, carotenoides, xantofilas e polifenóis são os principais pigmentos absorvedores de luz na região da luz visível. Quando as plantas estão sob estresse, a produção de clorofila diminui, resultando em pouca absorção de luz. Esse efeito foi observado com o aumento da reflectância na região do visível (B3 e B4) (Figura 27a). Na região do SWIR, o cafeeiro infestado apresenta reflectância maior que talhões sadios devido ao menor teor de água na planta e na estrutura do mesófilo.

Dados SAR podem fornecer informações quanto ao conteúdo de umidade e cobertura da vegetação, informações estas que podem auxiliar no monitoramento de doenças em culturas agrícolas (AGRAWAL e KHAIRNAR, 2019). O principal mecanismo responsável pelo retroespalhamento a partir da vegetação é o espalhamento volumétrico, nesse caso, é esperado que o retroespalhamento a partir da polarização cruzada  $\sigma^0VH$  seja um bom indicador das condições da vegetação. Considerando, as polarizações  $\sigma^0VV$  e  $\sigma^0VH$ , o cafeeiro infestado por nematoides é caracterizado por menores valores de retroespalhamento do que o cafeeiro sadio (Figura 27b). Quanto a polarização  $\sigma^0VH$ , esse comportamento é explicado pelo menor espalhamento volumétrico a partir de plantas infectadas devido a alterações na densidade da cobertura vegetal.

---

## Capítulo 4

### EXPERIMENTOS

#### 4.1 Experimento 1: Séries temporais de atributos ópticos e SAR para detecção de nematoides no cafeeiro

##### 4.1.1 Contextualização

Conforme já mencionado nos Capítulos 1 e 2, a disseminação de nematoides é um dos maiores obstáculos à produção de alimentos em todo o mundo, incorrendo em limitações aos processos de crescimento e produção das principais culturas agrícolas, dentre elas a do cafeeiro. Normalmente, a identificação de áreas infestadas é realizada a partir da coleta de amostras de solo, as quais são submetidas a análises laboratoriais para identificação da espécie e quantificação da população nas raízes da planta e no solo. Contudo, o comportamento responsivo do cafeeiro ao parasitismo por nematoides são frequentemente difíceis de detectar, uma vez que os sintomas são visíveis quando há comprometimento das raízes e, conseqüentemente, redução do desenvolvimento e baixa produtividade da planta (SALGADO; CARNEIRO; PINHO, 2011).

O sensoriamento remoto possibilita a detecção de áreas infestadas por nematoides, fornecendo informações que irão suportar medidas de manejo e controle mais eficazes. A detecção da infestação por patógenos a partir de sensoriamento remoto é pautada pela alteração da resposta espectral (reflectância) da vegetação, no caso de dados ópticos e pela alteração da estrutura da vegetação no caso de dados SAR. No entanto, a utilização do sensoriamento remoto para esse propósito é dificultada por diversos fatores. Primeiramente, o desenvolvimento do cafeeiro é dependente de variáveis bióticas e abióticas, e do efeito da bienalidade. E todos esses fatores podem influenciar no comportamento espectral do cafeeiro. Além de que, no caso do sensoriamento remoto óptico, a disponibilidade de dados em regiões com alta cobertura de nuvens é um fator limitante. Neste caso, a busca por dados complementares aos dados ópticos ainda é uma lacuna a ser explorada.

Diante do exposto, novos métodos são requeridos para contornar os obstáculos apontados anteriormente, especialmente para mapeamentos em grande escala. Dados no domínio temporal podem fornecer informações importantes no que diz respeito ao comportamento da cultura agrícola ao longo do seu ciclo de desenvolvimento. Além disso, ao analisar todo o ciclo de desenvolvimento da cultura é possível identificar períodos em que a planta é mais suscetível aos efeitos de doenças e pragas e, portanto, auxiliar a tomada de decisão no momento mais oportuno. Corroborando a isso, Arvor *et al.* (2011) afirmam que séries

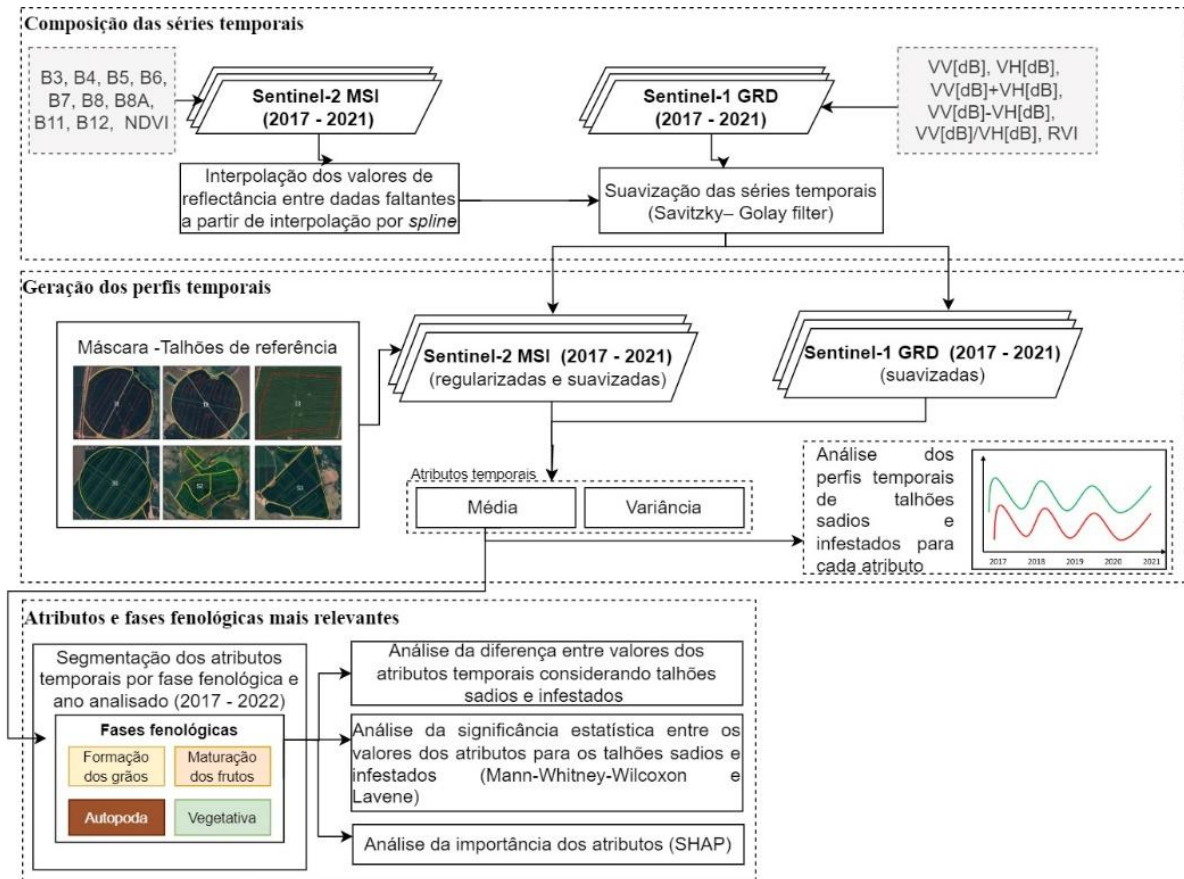
temporais de índices de vegetação permitem o monitoramento da fenologia e das variações intra-sazonais de áreas agrícolas. Quanto aos problemas relacionados a disponibilidade de imagens devido a cobertura de nuvens, os dados da missão Sentinel permitem a análise temporal de áreas agrícolas, principalmente, por disponibilizar dados no espectro micro-ondas com boa revisita temporal.

Face ao apresentado, nesta seção procura-se atender aos seguintes objetivos desta tese: Caracterizar os padrões fenológicos do cafeeiro sadio e infestado por nematoides a partir de séries temporais de atributos ópticos e SAR; e avaliar a contribuição de atributos extraídos de séries temporais de atributos ópticos e SAR na discriminação de áreas infestadas por nematoides, bem como identificar as fases fenológicas que favoreçam essa discriminação.

#### **4.1.2 Metodologia**

A metodologia adotada para alcançar os objetivos propostos, inicia-se pela composição das séries temporais, seguida pela análise dos perfis temporais dos atributos derivados das imagens Sentinel-1 e Sentinel-2. A terceira etapa compreende os processos para análise da separabilidade entre talhões sadios e infestados por nematoides. Por fim, foi gerado um *rank* dos atributos de maior relevância para detecção de nematoides na cultura do cafeeiro. Os processos metodológicos que descrevem essa seção são apresentados na Figura 28.

**Figura 28** - Métodos propostos para análise da discriminação entre talhões saudios e infestados a partir de atributos extraídos de séries temporais.



Fonte: Elaborado pelo autor.

#### 4.1.2.1 Análise dos perfis temporais de atributos extraídos de imagens ópticas e SAR

Conforme apresentado na Seção 3.2.1, 10 imagens excederam o limiar de cobertura de nuvens admissível, as quais se referem aos meses de janeiro, maio e outubro de 2017, janeiro e novembro de 2018, janeiro a março de 2020, e dezembro de 2021. Diante disso, o interpolador *spline* de ordem 2 foi utilizado para preencher as datas faltantes. A interpolação por *splines* é uma alternativa aos diferentes métodos para interpolação de dados, uma vez que o erro de interpolação pode ser consideravelmente menor mesmo quando é utilizado polinômios de baixo grau (WANG, 2013). Para estimar os valores dos atributos ópticos para as datas faltantes, a interpolação por *splines* consistiu em determinar um polinômio de segunda ordem para cada intervalo a ser interpolado.

Após a interpolação das séries temporais, a máscara contendo os polígonos de referência que indicam os talhões saudios e infestados indicados na Figura 22 (Seção 3.1.2) foi aplicada a cada atributo óptico e SAR para construção das séries temporais das áreas de referência (I1, I2,

I3, S1, S2 e S3). Desse modo, os perfis temporais foram construídos a partir dos valores médios mensais de cada área de referência.

Para apresentação dos perfis temporais, foi aplicado aos atributos ópticos e SAR o filtro Savitzky-Golay (SG) (SAVITZKY e GOLAY, 1964) para reduzir a influência de *outliers* nos valores de reflectância e nos coeficientes de retroespalhamento. O filtro SG é normalmente utilizado para suavizar um sinal ruidoso, eliminando pequenas variações e mantendo a forma geral do sinal. Esse procedimento de filtragem é realizado conforme Equação 18.

$$Y_j = \frac{1}{N} \sum_{i=-m}^m C_i y_{j+1} \quad (18)$$

Em que  $y$  é o sinal original,  $Y_j$  é o sinal suavizado,  $C_i$  se refere a janela de suavização,  $N$  é o número de pontos da janela de suavização, sendo  $N = 2m + 1$  quando o número da janela de suavização é ímpar, e  $m$  é a metade do valor da janela de pontos ( $N/2$ ). Para os perfis temporais de atributos ópticos e SAR foi utilizado o filtro SG com janela de 3x3.

Após as etapas de regularização e suavização das séries temporais de cada atributo derivado das imagens ópticas e SAR, foram gerados perfis temporais com base nos valores médios mensais de cada atributo. Com o objetivo de compreender o comportamento sazonal de áreas sadias e infestadas, os perfis temporais que serão apresentados nesta tese se referem aos perfis da média mensal de cada atributo. No entanto, as demais etapas que abrangem esse capítulo consideram o atributo variância média mensal. Sendo assim, para análise dos perfis temporais foram consideradas duas abordagens:


- (1) Perfis temporais considerando 1 ciclo fenológico (2019 -2020). Essa abordagem teve por objetivo compreender, de modo preliminar, o comportamento sazonal do cafeeiro a partir de atributos ópticos e SAR. Para isso, foi gerado o perfil temporal do atributo NDVI para caracterizar o comportamento do cafeeiro a partir de dados ópticos, e no caso dos atributos SAR foram utilizadas as polarizações  $\sigma^0VV$  e  $\sigma^0VH$ . Cabe destacar que para a geração dos perfis temporais, foi considerado os valores médios dos talhões sadios.
- (2) Perfis temporais considerando o comportamento sazonal de cada área sadia (S1, S2, S3) e infestada (I1, I2, I3) por nematoides ao longo de 5 anos (2017 – 2021).

#### 4.1.2.2 Análise da separabilidade entre talhões sadios e infestados

Com o intuito de identificar os atributos e fases fenológicas apropriadas à discriminação de talhões sadios e infestados, as séries temporais de atributos foram sintetizadas por fases fenológicas (formação de grãos, maturação dos frutos, autopoda e vegetativa). Esse procedimento foi realizado a partir do cálculo dos valores mensais de média e variância para cada um dos atributos explorados nesta pesquisa, considerando as diferentes fases fenológicas (Figura 29). À vista disso, a análise da separabilidade foi realizada em duas etapas:

- (1) Análise da magnitude das diferenças detectadas entre áreas sadias e infestadas em cada fase fenológica; e
- (2) Análise da significância estatística das diferenças estimadas na Etapa 1.

**Figura 29** - Representação esquemática das séries temporais de atributos ópticos e SAR. As linhas em verde ilustram áreas com cafeeiros sadios e as linhas em vermelho ilustram áreas infestadas por nematoides. Os retângulos em amarelo, laranja, marrom e verde indicam as fases de formação dos grãos, maturação dos frutos, autopoda e vegetativa, respectivamente. As letras representam as iniciais dos meses que compõem cada fase fenológica.



Fonte: Elaborado pelo autor.

A primeira etapa iniciou-se pelo cálculo dos valores médios e de variância mensais de cada área de referência. Em seguida, foi calculado uma média entre os meses que caracterizam cada fenológica, de modo a obter um valor único para o cafeeiro sadio e infestado em cada fase do ciclo de desenvolvimento do cafeeiro. A partir disso, foi calculada a discrepância entre os valores médios de cada atributo por fase fenológica.

A segunda etapa, por sua vez, foi avaliada a partir de métodos estatísticos. Para isso, foram testados os valores médios que caracterizam cada fase fenológica em cada um dos atributos analisados. Inicialmente os dados foram testados quanto à normalidade, aleatoriedade e independência. Diferentes metodologias podem ser aplicadas para avaliar a normalidade de uma amostra, dentre elas a utilizada nesta pesquisa foi o algoritmo Shapiro-Wilk. O teste de Shapiro-Wilk é reconhecido por possuir boa capacidade em testes quanto a normalidade em comparação com outros testes, especialmente para amostras pequenas.

---

Para avaliar se as diferenças observadas entre dois grupos são significativas, normalmente, são utilizados testes estatísticos. Os testes mais conhecidos que lidam com essas questões são o teste t de *Student* (comparação de médias) e o teste F (comparação de variâncias). Contudo, ambos pressupõem que os dados sejam normalmente distribuídos. Por esse motivo, como não foi identificada normalidade nos dados, foi utilizado um teste-t não paramétrico (Mann-Whitney-Wilcoxon (MWW),  $\alpha = 0,05$ ) para avaliar se talhões sadios e infestados possuem a mesma medida de tendência central (mediana). O teste MWW é útil quando o tamanho dos dados é pequeno e não seguem uma distribuição normal (MANN e WHITNEY, 1947). Além disso, o teste não requer grupos de amostras de tamanhos iguais. Para avaliar a diferença estatística entre a variância de áreas sadias e infestadas, foi utilizado um teste-f não paramétrico (Teste de Levene,  $\alpha = 0,05$ ) (BROWN e FORSYTHE, 1974). O teste de Lavene avalia as suposições se dois grupos possuem a mesma variância.

#### 4.1.2.3 Análise da importância dos atributos

Devido à grande quantidade de atributos que podem ser gerados a partir de dados ópticos e SAR, é recomendado que sejam aplicados métodos de seleção de atributos para melhorar a acurácia de processamentos e diminuir o efeito da alta dimensionalidade de dados. Ur Rahman *et al.* (2017) destacam que a seleção de um conjunto de dados adequado para discriminar informação de interesse é um dos principais problemas para identificar doenças específicas em culturas agrícolas. Além disso, Akbari *et al.* (2020) destacam que é de extrema importância reduzir a redundância de dados para discriminar diferentes culturas, particularmente em casos complexos de cobertura do solo.

Para identificar os atributos e fases fenológicas que favorecem a discriminação entre talhões sadios e infestados, foi gerado um *rank* de importância dos atributos. Para tanto, os atributos temporais foram agrupados com base nas fases fenológicas (formação de grãos, maturação dos frutos, autopoda e vegetativa). Esse *rank* de atributos foi gerado a partir da abordagem *Shapley Additive exPlanations* (SHAP), utilizada para explicar a saída de modelos de aprendizado de máquina (LUNDBERG e LEE, 2017). Neste caso, foi utilizado o método SHAP do tipo *TreeExplainer* para explicar a saída de um modelo *Random Forest* (RF). Basicamente, o método SHAP calcula a importância dos atributos de entrada comparando qual será o resultado do modelo se um determinado atributo é incluído (ou não), considerando todas as permutações possíveis do vetor de entrada de atributos. As formulações matemáticas para obtenção dos valores SHAP são apresentadas nas Equações 19, 20 e 21.

$$g(x') = \varphi_0 + \sum_{i=1}^M \varphi_i x'_i \quad (19)$$

$$\varphi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} [f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S)] \quad (20)$$

$$\frac{1}{n} \sum_{i=1}^n |\varphi_j^{(i)}| \quad (21)$$

Em que  $g(x')$  é o modelo de explicação,  $x' \in \{0,1\}^M$  são os dados de treinamento e  $M$  é o número de atributos de entrada (Equação 20). Esse método atribui um peso ( $\varphi_i \in \mathbb{R}$ ) a cada atributo, e a soma de todos os pesos aproximam a resposta do modelo original (neste caso, *Random Forest*) que se pretende explicar. A variável  $\varphi_0$  representa um valor constante quando todas as entradas estão ausentes. Contudo como a ordem em que um atributo é selecionado em algoritmos de árvore de decisão, por exemplo, pode influenciar na saída do modelo, o método SHAP propõe que o modelo seja treinado com todos os subconjuntos de atributos possíveis. Ou seja, para calcular  $\varphi_i$  (Equação 21), este método requer o retreinamento do modelo em todos os subconjuntos de atributos  $S \subseteq F$ , onde  $F$  é o conjunto de todos os atributos e  $x_S$  representa os valores dos atributos de entrada no conjunto  $S$ . Por fim, os atributos com a maior média de contribuição em relação a todas as combinações de atributos são os mais importantes (Equação 22). Logo, o valor SHAP é a contribuição marginal de um atributo entre todas as permutações possíveis.

### 4.1.3 Resultados e discussões

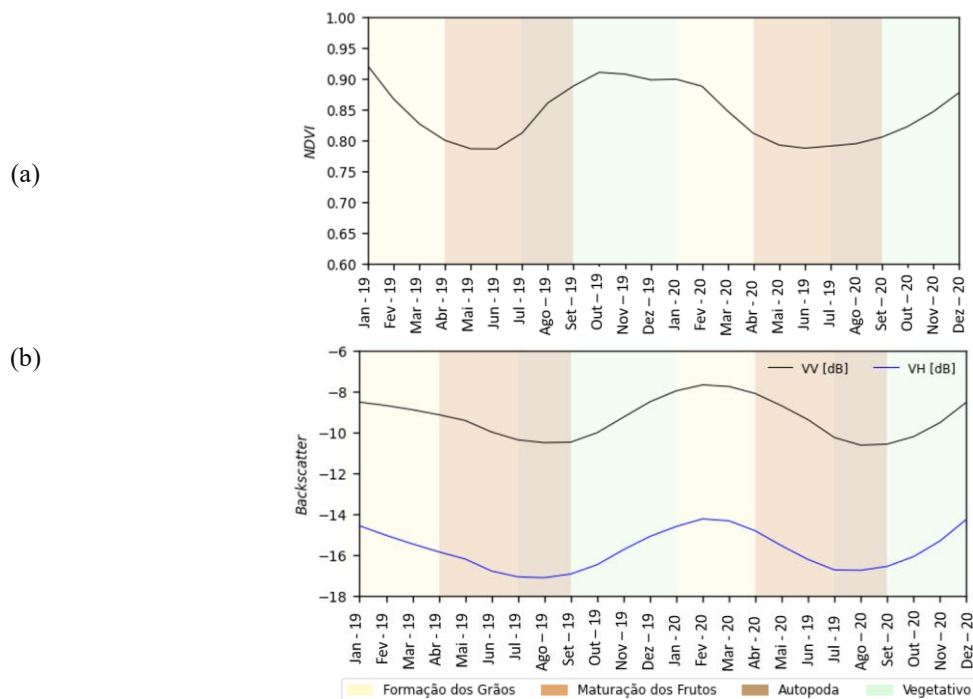
Nesta seção, são apresentados os resultados obtidos nas análises dos atributos extraídos das séries temporais de imagens ópticas e SAR, as quais podem ser categorizadas quanto a forma de análise em: análise dos perfis temporais; análise da separabilidade entre talhões sadios e infestados a partir de atributos extraídos de séries temporais; e análise da importância dos atributos. Das análises realizadas, a primeira teve por objetivo, a partir de análise visual, verificar a separabilidade entre os alvos de interesse, considerando o comportamento da série temporal. A segunda teve por objetivo a validação estatística da separabilidade entre áreas sadias e infestadas em relação aos diversos atributos explorados nesta pesquisa. Por fim, a terceira focou na hierarquização dos atributos, por meio de análise de suas importâncias ranqueadas a partir da metodologia SHAP.

#### 4.1.3.1 Comportamento sazonal do cafeeiro ao longo de seu ciclo fenológico

Os resultados apresentados nesta seção visam apresentar os perfis temporais gerados a partir dos atributos derivados das imagens ópticas e SAR. Assim sendo, as análises foram realizadas conforme descrito na Seção 4.1.2.1.

Para melhor compreensão das análises dos perfis temporais produzidos deve-se compreender o comportamento sazonal do cafeeiro ao longo de seu ciclo de desenvolvimento. Segundo (CAMARGO, 1998), as fases do cafeeiro podem ser esquematizadas considerando o período de 12 meses, da seguinte forma: (1) formação dos grãos entre janeiro e abril; (2) maturação dos frutos de abril a julho; (3) autopoda entre os meses de julho e agosto; e (4) vegetativa de setembro a dezembro. Na Figura 30, são apresentados os perfis temporais gerados a partir dos atributos NDVI,  $\sigma^0VV$  e  $\sigma^0VH$ , para os quais foi considerado o período de dois anos. O perfil temporal do atributo NDVI foi utilizado para caracterizar o comportamento do cafeeiro a partir de dados ópticos, uma vez que o NDVI pode ser utilizado como uma inferência ao vigor vegetativo. No caso dos atributos SAR, foram utilizadas as polarizações  $\sigma^0VV$  e  $\sigma^0VH$

**Figura 30** - Perfis temporais, entre os anos de 2019 e 2020, dos valores médios mensais dos atributos NDVI (a) e coeficientes de retroespalhamento das polarizações  $\sigma^0VV$  e  $\sigma^0VH$  (b) durante as principais fases fenológicas do cafeeiro.



A partir dos gráficos da Figura 30 é possível analisar o comportamento sazonal do cafeeiro. Na fase de formação dos grãos ocorre a redução gradual dos valores de NDVI. A fase

---

de maturação dos frutos é caracterizada por estabilização dos valores de NDVI. Na fase autopoda alguns ramos de produção do cafeeiro secam e morrem e, conseqüentemente, há diminuição dos valores de NDVI. No entanto, para a área de estudo grande parte das áreas produtoras de café são irrigadas e por isso esse efeito não é tão evidente (Figura 30a). Por fim, na fase vegetativa o cafeeiro começa a apresentar brotos e novas folhas, com NDVI aumentando gradativamente até atingir seu máximo em meados do mês de novembro (Figura 30a).

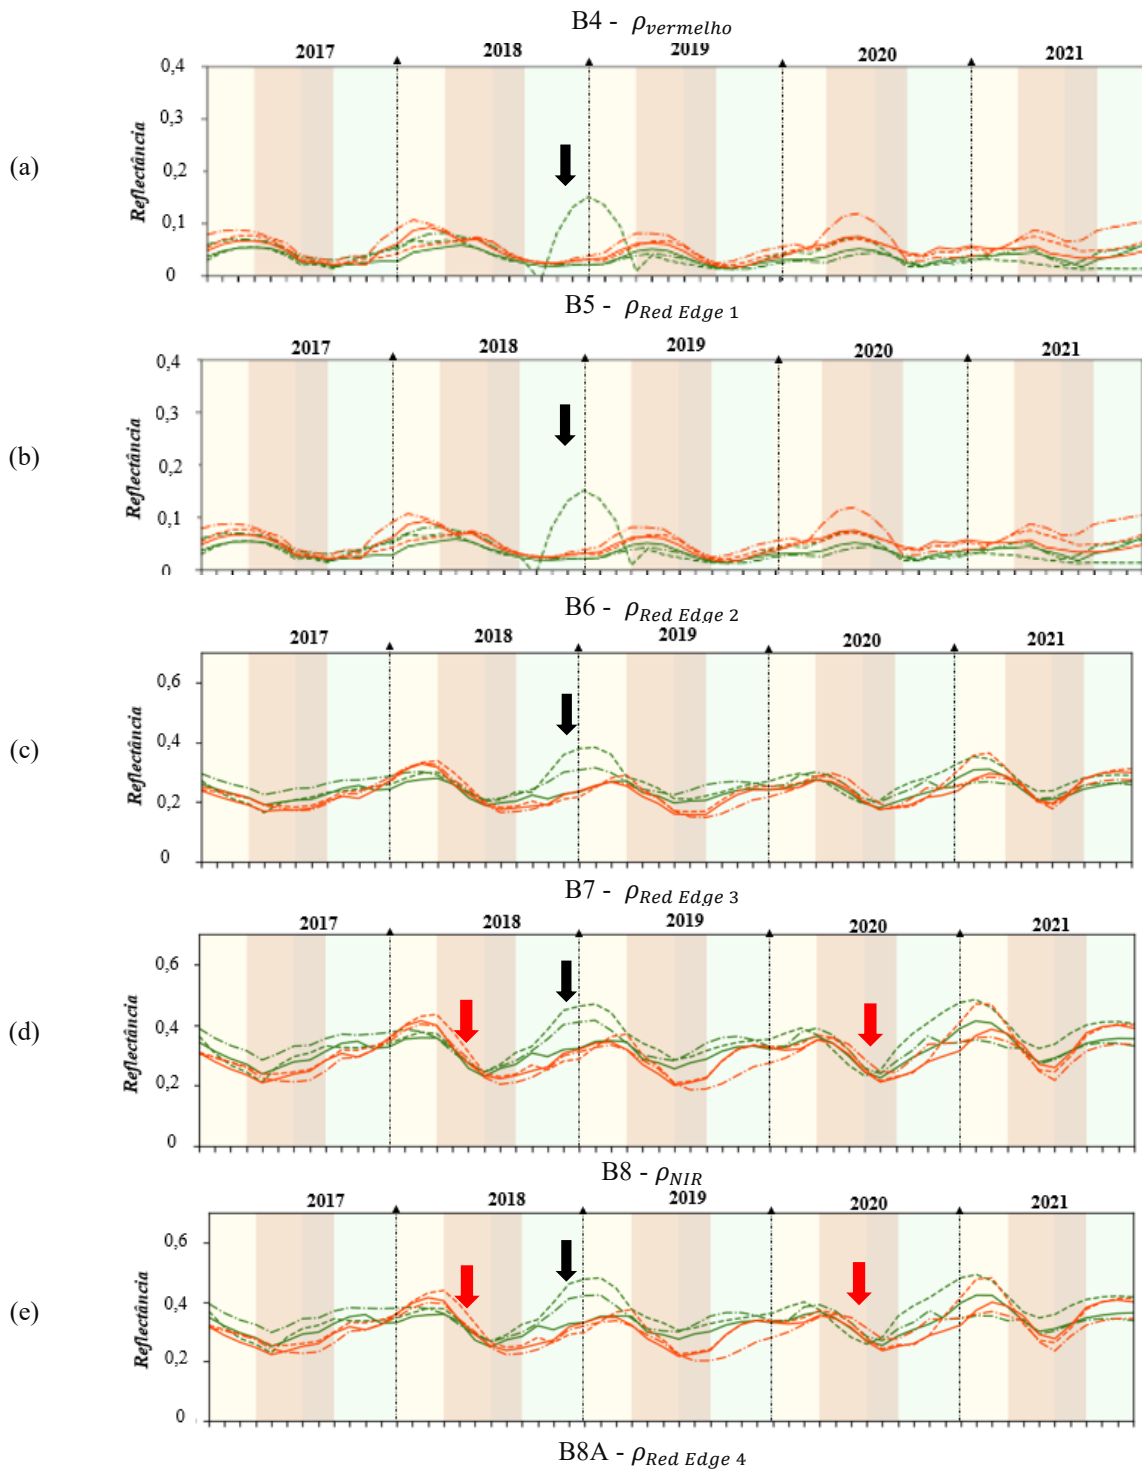
Em relação ao comportamento sazonal dos coeficientes de retroespalhamento de  $\sigma^0VV$  e  $\sigma^0VH$  (Figura 30b), foi observada uma redução do retroespalhamento na fase de formação dos grãos até a fase de autopoda, com subsequente aumento dos valores de  $\sigma^0VV$  e  $\sigma^0VH$  a partir da fase vegetativa, atingindo seu máximo em meados da fase de formação de grãos. Como houve um aumento na estrutura da planta durante as fases vegetativa e de formação de grãos devido ao crescimento de novos ramos, folhas e desenvolvimento de frutos, os coeficientes de retroespalhamento de  $\sigma^0VV$  e  $\sigma^0VH$  atingem valores mais altos. As variações sazonais nos coeficientes de retroespalhamento são suaves ao longo do ciclo de desenvolvimento do cafeeiro, o que pode estar relacionado ao cafeeiro ser uma cultura perene. Assim, o aumento do retroespalhamento está mais relacionado ao aumento da copa da planta durante o período vegetativo e formação dos grãos. Além disso, deve-se considerar a contribuição da precipitação durante este período, uma vez que há aumento dos coeficientes de retroespalhamento,  $\sigma^0VV$  e  $\sigma^0VH$ , com o aumento do teor de umidade superficial.

De modo geral, para os 2 anos analisados (2019 – 2020) têm-se que os valores médios do NDVI e das polarizações  $\sigma^0VV$  e  $\sigma^0VH$  seguiram o ciclo produtivo do cafeeiro, além de acompanhar as variações climáticas ao longo do ano. Assim sendo, os menores valores são verificados nos meses que precedem o período chuvoso e os maiores valores ocorreram durante as fases em que a disponibilidade de água no solo é maior, ou seja, as fases de formação dos grãos e vegetativa.

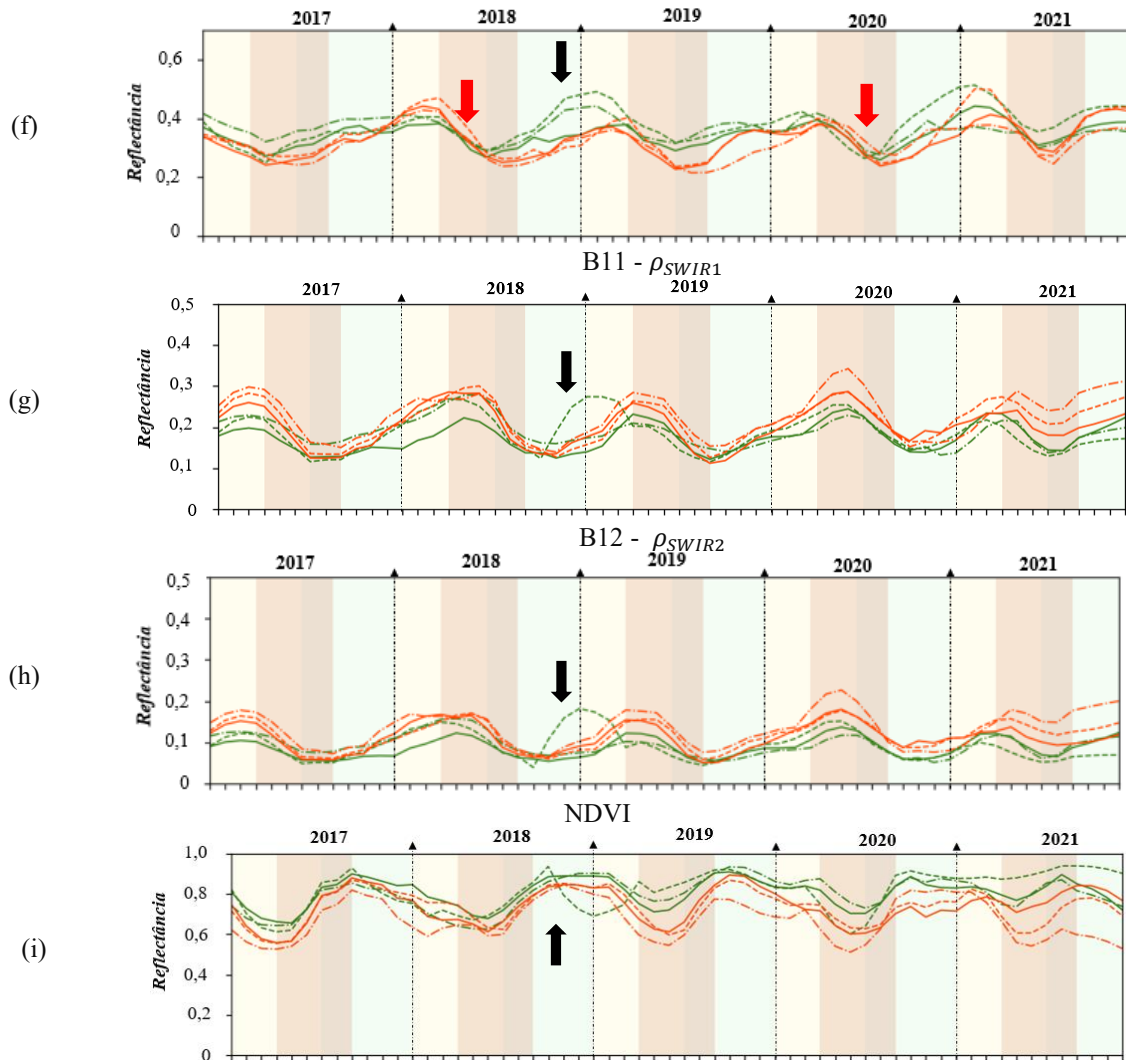
A fim de analisar o comportamento sazonal e a possibilidade de discriminar talhões sadios e infestados por nematoides, a partir dos diferentes atributos extraídos, foram gerados perfis temporais para o período compreendido entre os anos de 2017 e 2021. Os perfis temporais para cada atributo óptico estão apresentados na Figura 31, nos quais estão representadas as fases fenológicas do cafeeiro. As barras em amarelo, laranja, marrom e verde representam as fases de formação dos grãos, maturação dos frutos, autopoda e vegetativa, respectivamente. De antemão, cabe destacar que mesmo após a utilização dos algoritmos Savitzky–Golay e *spline*,

as séries temporais de atributos ópticos apresentaram *outliers*, conforme indicado em preto na Figura 31.

**Figura 31** – Perfis temporais dos valores médios dos atributos: (a) B4 (vermelho), (b) B5 (*red-edge* 1), (c) B6 (*red-edge* 2), (d) B7 (*red-edge* 3), (e) B8 (NIR), (f) B8A (*red-edge* 4), (g) B11 (SWIR 1), (h) B12 (SWIR 2), e (i) NDVI. As linhas verdes e vermelhas representam os talhões saudios e infestados, respectivamente (continua).



**Figura 31** – Perfis temporais dos valores médios dos atributos: (a) B4 (vermelho), (b) B5 (*red-edge* 1), (c) B6 (*red-edge* 2), (d) B7 (*red-edge* 3), (e) B8 (NIR), (f) B8A (*red-edge* 4), (g) B11 (SWIR 1), (h) B12 (SWIR 2), e (i) NDVI. As linhas verdes e vermelhas representam os talhões saudios e infestados, respectivamente (continua).



Fonte: Elaborado pelo autor.

Os perfis temporais apresentados na Figura 31 mostram que os atributos ópticos são capazes de reproduzir os padrões sazonais do ciclo fenológico do cafeeiro. Além disso, foram observadas pequenas variações entre áreas saudias e infestadas, ao longo das séries temporais. Para os perfis temporais do atributo B4 (vermelho – 664,6 nm) (Figura 31a), de modo geral, nota-se que os talhões infestados apresentam resposta espectral ligeiramente superior às respostas verificadas para os talhões saudios. Ainda assim, visualmente, não é possível perceber separabilidade entre os alvos de interesse. Esse mesmo comportamento é verificado no perfil temporal do atributo B5 (*red-edge* 1 – 704,1 nm) (Figura 31b).

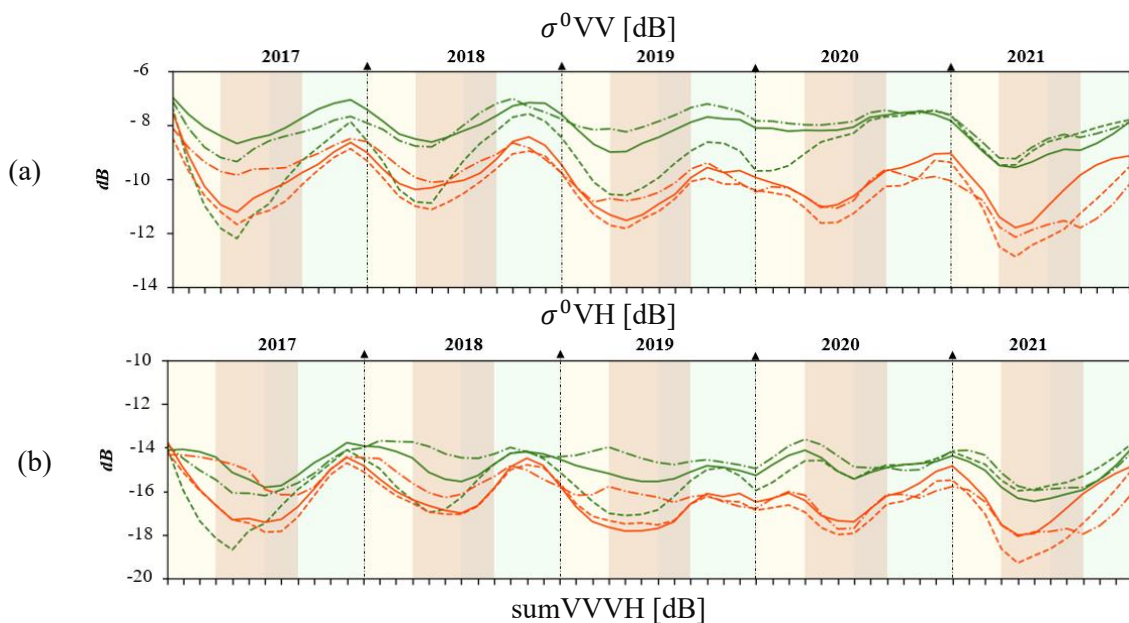
Já para o atributo B6 (*red-edge* 2 – 740,5 nm) (Figura 31c), nota-se uma leve diferenciação durante a fase vegetativa, nos quais os talhões saudios apresentam maiores valores

de reflectância se comparados àqueles apresentados para os talhões infestados. Em relação aos perfis temporais dos atributos B7 (*red-edge* 3 – 782,8 nm) (Figura 31d), B8 (NIR – 832,8 nm) (Figura 31e) e B8A (*red-edge* 4 – 864,7 nm)(Figura 31f), embora pouco expressiva, a diferenciação entre os alvos ocorre para quase todo o período analisado, com exceção dos pontos destacados pelas setas em vermelho nas referidas figuras.


A reflectância dos talhões sadios é menor que a reflectância de talhões infestados nos atributos B11 (SWIR1 – 1613,7 nm)(Figura 31g) e B12 (SWIR 2 – 2202,4 nm)(Figura 31h). Na região do SWIR, durante a fase de maturação dos frutos, talhões infestados apresentaram reflectância maior que talhões sadios, sendo esse período caracterizado por baixa precipitação na área de estudo. Após esse período, durante a fase vegetativa, quando há aumento da precipitação, talhões sadios e infestados assumiram valores similares de reflectância. Por fim, para o atributo NDVI, apresentado na Figura 31i, nota-se que os talhões sadios apresentam valores mais elevados que àqueles apresentados para as áreas infestadas. Esse comportamento é esperado uma vez que a vegetação sob algum estresse tende a apresentar menor vigor vegetativo e, conseqüentemente, menores valores de NDVI.

Os perfis temporais extraídos a partir dos atributos SAR são apresentados na Figura 32. Assim como na Figura 31, as barras em amarelo, laranja, marrom e verde representam as fases de formação dos grãos, maturação dos frutos, autopoda e vegetativa, respectivamente.

**Figura 32** – Perfis temporais dos atributos polarimétricos SAR (a)  $\sigma^0_{VV}$  [dB], (b)  $\sigma^0_{VH}$  [dB], (c) sumVVVH [dB] (d) subVVVH [dB], (e) ratioVVVH [dB], e (f) RVI. As linhas verdes e vermelhas representam os talhões sadios e infestados, respectivamente (Continua).



**Figura 32** – Perfis temporais dos atributos polarimétricos SAR (a)  $\sigma^0$ VV [dB], (b)  $\sigma^0$ VH [dB], (c) sumVVVH [dB] (d) subVVVH [dB], (e) ratioVVVH [dB], e (f) RVI. As linhas verdes e vermelhas representam os talhões sadios e infestados, respectivamente (Continua).



De acordo com os perfis temporais apresentados na Figura 32a, Figura 32b, Figura 32c e Figura 32d, os coeficientes de retroespalhamento ( $\sigma^0$ ) de talhões infestados são menores que os dos talhões sadios. Em relação à polarização  $\sigma^0$ VH, esse comportamento pode ser explicado pelo menor espalhamento volumétrico causado pelas plantas infectadas, devido às alterações no dossel da vegetação. Os coeficientes de retroespalhamento de  $\sigma^0$ VV e  $\sigma^0$ VH diminuíram da fase de formação de grãos até a fase de autopoda, atingindo seu pico na fase vegetativa. Como há aumento da estrutura da planta durante a fase vegetativa e de formação de grãos, os maiores valores de retroespalhamento nessas fases podem ser relacionados com o crescimento de novos ramos, folhas e desenvolvimento dos frutos.

O comportamento do coeficiente de retroespalhamento para cada fase fenológica do cafeeiro pode ser resumido da seguinte forma: Na fase de formação dos grãos, os coeficientes de retroespalhamento de  $\sigma^0VV$  e  $\sigma^0VH$  permaneceram relativamente estáveis. Talhões sadios apresentaram valores de retroespalhamento de aproximadamente  $\sim -8$  dB em  $\sigma^0VV$  e  $-22$  dB em  $\sigma^0VH$ , enquanto talhões infestados apresentaram valores de  $\sim -10$  dB em  $\sigma^0VV$  e  $\sim -25$  dB em  $\sigma^0VH$ . Após esta etapa, durante a fase de maturação dos frutos, os valores de retroespalhamento dos talhões sadios mantêm-se similares aos valores observados na fase de formação de grãos, tanto em  $\sigma^0VV$  quanto em  $\sigma^0VH$ . Por outro lado, observou-se uma redução nos valores de retroespalhamento dos talhões infestados, atingindo  $\sim -12$  dB em  $\sigma^0VV$  e  $\sim -31$  dB em  $\sigma^0VH$ . Os menores valores de retroespalhamento foram alcançados na fase de autopoda, sendo esta variação mais evidente nos talhões infestados. Finalmente, durante a fase vegetativa, os valores de retroespalhamento aumentaram novamente, atingindo o máximo em janeiro. Esse comportamento é semelhante ao observado por Soudani *et al.* (2021), e os autores justificam o aumento dos valores de retroespalhamento de florestas caducifólias, durante a fase vegetativa, em razão do aumento do espalhamento volumétrico da vegetação.

Para o atributo  $\text{sumVVVH}$  (Figura 32c), talhões sadios alcançaram valores mais altos que talhões infestados, especialmente durante a fase vegetativa. Para o atributo  $\text{subVVVH}$  (Figura 32d), a diferenciação entre os alvos é menos perceptível do que no atributo  $\text{sumVVVH}$ , ainda assim é durante a fase vegetativa que áreas sadias e infestadas apresentam maior separabilidade. Quanto aos perfis dos atributos  $\text{ratioVVVH}$  e  $\text{RVI}$  (Figura 32e e Figura 32f), o comportamento verificado para os demais atributos SAR se inverte, talhões infestados apresentam valores superiores aos talhões sadios. Dentre esses atributos, é o  $\text{RVI}$  que apresenta menor separabilidade entre os alvos, principalmente entre as fases de formação dos grãos e maturação dos frutos.


Os resultados até aqui apresentados mostram evidências de que áreas sadias e áreas infestadas podem ser discriminadas a partir de dados SAR. Diante disso, as análises realizadas na Seção 4.1.3.2 permitirão confirmar as suposições aqui apontadas.

#### **4.1.3.2 Separabilidade entre talhões sadios e infestados a partir de séries temporais de atributos ópticos e SAR**

Os dados utilizados para análise da separabilidade entre áreas sadias e infestadas foram avaliados, conforme descrito na Seção 4.1.2.2. Os resultados da análise de separabilidade para os atributos ópticos são apresentados na Figura 33 e Figura 34, e os resultados obtidos para os atributos SAR são apresentados na Figura 35 e Figura 36. Cabe destacar que os dados que

originaram os gráficos apresentados na Figura 33 e Figura 34 são apresentados no Apêndice A. Por sua vez, os resultados dos testes estatísticos para os atributos ópticos são apontados na Tabela 10 e Tabela 11, e para os dados SAR os resultados estão indicados na Tabela 12 e Tabela 13.

**Figura 33** - Diferença nos valores médios dos atributos ópticos de talhões sadios e infestados por nematoides. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa.



Fonte: Elaborado pelo autor.

**Tabela 10** - P-valor obtido a partir do teste MWW indicando a significância das diferenças dos atributos ópticos (média). FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao  $p\text{-valor} \leq 0,05$ .

|      | Fases | B4     | B5     | B6     | B7     | B8     | B8A    | B11     | B12     | NDVI   |
|------|-------|--------|--------|--------|--------|--------|--------|---------|---------|--------|
| 2017 | FG    | 0.0117 | 0.039  | 0.0039 | 0.0039 | 0.0039 | 0.0039 | 0.0039  | 0.0039  | 0.0078 |
|      | MF    | 0.0039 | 0.0195 | 0.0039 | 0.0039 | 0.0039 | 0.0039 | 0.0039  | 0.0039  | 0.0039 |
|      | AP    | 0.1562 | 0.6875 | 0.0312 | 0.0312 | 0.0312 | 0.0312 | 0.562   | 0.3125  | 0.0625 |
|      | VG    | 0.9697 | 0.791  | 0.0034 | 0.0014 | 0.0009 | 0.0024 | 0.3803  | 0.3012  | 0.3804 |
| 2018 | FG    | 0.25   | 0.1289 | 0.0078 | 0.0117 | 0.0117 | 0.0117 | 0.0039  | 0.0546  | 0.25   |
|      | MF    | 0.0976 | 0.2031 | 0.0195 | 0.0195 | 0.0195 | 0.0195 | 0.0039  | 0.0039  | 0.7343 |
|      | AP    | 0.0312 | 0.8437 | 0.0625 | 0.0625 | 0.0625 | 0.0625 | 0.0625  | 0.0312  | 0.0312 |
|      | VG    | 0.622  | 0.2661 | 0.0004 | 0.0004 | 0.0004 | 0.0004 | 0.2661  | 0.9697  | 0.0009 |
| 2019 | FG    | 0.9101 | 0.5703 | 0.0195 | 0.0039 | 0.0039 | 0.0039 | 1       | 0.8203  | 0.1289 |
|      | MF    | 0.0078 | 0.039  | 0.0273 | 0.0117 | 0.0117 | 0.0117 | 0.0039  | 0.0039  | 0.0078 |
|      | AP    | 0.0312 | 0.0625 | 0.0312 | 0.0312 | 0.0312 | 0.0312 | 0.0312  | 0.0312  | 0.0312 |
|      | VG    | 0.0034 | 0.4238 | 0.0004 | 0.0004 | 0.0004 | 0.0004 | 0.1098  | 0.0068  | 0.0048 |
| 2020 | FG    | 0.0039 | 0.0546 | 0.0039 | 0.0039 | 0.0039 | 0.0039 | 0.0039  | 0.0039  | 0.0039 |
|      | MF    | 0.0039 | 0.0039 | 0.3593 | 0.8203 | 0.8203 | 0.8203 | 0.0039  | 0.0039  | 0.0742 |
|      | AP    | 0.0312 | 0.0312 | 1      | 0.8437 | 0.5625 | 0.5625 | 0.03125 | 0.03125 | 0.0312 |
|      | VG    | 0.0004 | 0.0161 | 0.0122 | 0.0161 | 0.0161 | 0.0122 | 0.0004  | 0.0004  | 0.0005 |
| 2021 | FG    | 0.0078 | 0.0117 | 0.9101 | 0.6523 | 0.6523 | 0.6523 | 0.0195  | 0.0039  | 0.0078 |
|      | MF    | 0.0039 | 0.0039 | 0.3007 | 0.164  | 0.164  | 0.164  | 0.0039  | 0.0039  | 0.0195 |
|      | AP    | 0.0312 | 0.0312 | 0.0625 | 0.0312 | 0.0312 | 0.0312 | 0.0312  | 0.0312  | 0.0312 |
|      | VG    | 0.0009 | 0.0004 | 0.0922 | 0.5693 | 0.7333 | 0.7333 | 0.0004  | 0.0004  | 0.0048 |

Fonte: Elaborado pelo autor.

---

Ao analisar o gráfico apresentado na Figura 33, nota-se baixos valores de discrepância para os atributos B4 (vermelho) e B5 (*red-edge 1*), porém, de acordo com a Tabela 10, esses atributos produziram valores de diferenças estatisticamente discrimináveis em determinados períodos fenológicos, como por exemplo, durante a fase de maturação dos frutos (MF) em quatro dos cinco anos analisados.


Com exceção do atributo B6 (*red-edge 2*), os atributos B7 (*red-edge 3*), B8 (NIR) e B8A (*red-edge 4*) apresentaram valores similares de discrepância durante as fases fenológicas. Sendo os menores valores verificados durante a fase de autopoda (AP) em 2020 e formação dos grãos (FG) em 2021. Esse comportamento é evidente na Tabela 10, onde o atributo B7, por exemplo, não apresentou significância estatística nessas fases e chegou a atingir  $p$ -valor = 0,84 em 2020 durante a fase AP, e  $p$ -valor = 0,65 durante a fase FG em 2021.

Os atributos B11 (SWIR 1) e B12 (SWIR 2) apresentaram valores de discrepância inferiores a 0,02 durante as fases fenológicas VG e FG nos anos de 2017 e 2018, porém apresentam valores de discrepância superiores a 0,04 na fase MF para os demais anos (2019, 2020 e 2021). Esse comportamento é indicado pelos valores apresentados na Tabela 10, na qual se pode verificar que para a fase VG de 2017 o  $p$ -valor foi igual a 0,3803 e 0,3012 em B11 e B12, respectivamente. De forma análoga, em 2018 obteve-se  $p$ -valor de 0,2661 e 0,2697 para B11 e B12, respectivamente. O atributo NDVI demonstrou comportamento discrepante dos demais atributos. A partir de 2019, os valores de discrepância foram consideravelmente superiores aos observados nos anos anteriores. Apesar disso, as maiores discrepâncias são observadas durante as fases AP e VG. Com exceção do ano de 2017, a fase AP apresentou  $p$ -valor < 0,05 durante todo o período analisado.

Por fim, pode-se notar que, em relação às fases fenológicas, os atributos B6, B7, B8 e B8A apresentam valores estatisticamente significativos para as fases FG e VG, com exceção do ano de 2021. Já os atributos B11 e B12 demonstraram ser estatisticamente diferentes durante a fase MF em todo o período avaliado. Por fim, o atributo NDVI apresentou diferença estatística durante as fases de AP e VG, com exceção de 2017.

A Figura 34 e a Tabela 11 apresentam as discrepâncias dos valores médios da variância, calculadas a partir de séries temporais dos atributos ópticos.

**Figura 34** - Diferença nos valores de variância dos atributos ópticos de talhões sadios e infestados por nematoides. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa.



Fonte: Elaborado pelo autor.

**Tabela 11** - P-valor obtido a partir do teste de Lavene indicando significância dos valores de variância dos atributos ópticos. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao p-valor  $\leq 0,05$ .

|      | Fases | B4     | B5     | B6     | B7     | B8     | B8A    | B11    | B12    | NDVI   |
|------|-------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 2017 | FG    | 0.0886 | 0.0627 | 0.1898 | 0.0762 | 0.0801 | 0.092  | 0.0089 | 0.0189 | 0.0353 |
|      | MF    | 0.2666 | 0.2887 | 0.371  | 0.3879 | 0.319  | 0.2429 | 0.0776 | 0.0665 | 0.0401 |
|      | AP    | 0.2225 | 0.2227 | 0.2789 | 0.9564 | 0.4956 | 0.3476 | 0.1687 | 0.1828 | 0.0176 |
|      | VG    | 0.5712 | 0.7706 | 0.0516 | 0.0152 | 0.0128 | 0.0112 | 0.1494 | 0.8718 | 0.9096 |
| 2018 | FG    | 0.5885 | 0.7346 | 0.0165 | 0.005  | 0.0119 | 0.0128 | 0.1489 | 0.9855 | 0.9596 |
|      | MF    | 0.8377 | 0.9689 | 0.0237 | 0.0098 | 0.0039 | 0.0024 | 0.1865 | 0.9682 | 0.9055 |
|      | AP    | 0.0969 | 0.0671 | 0.05   | 0.132  | 0.1458 | 0.1545 | 0.0222 | 0.096  | 0.146  |
|      | VG    | 0.0548 | 0.0555 | 0.0441 | 0.0645 | 0.0527 | 0.0933 | 0.0597 | 0.0608 | 0.0537 |
| 2019 | FG    | 0.0684 | 0.0683 | 0.1621 | 0.1027 | 0.1497 | 0.2939 | 0.0787 | 0.0752 | 0.0669 |
|      | MF    | 0.1541 | 0.1541 | 0.0106 | 0.001  | 0.2701 | 0.5311 | 0.1764 | 0.1685 | 0.1781 |
|      | AP    | 0.3242 | 0.1128 | 0.0008 | 0.2841 | 0.0004 | 0.2444 | 0.4957 | 0.5618 | 0.7334 |
|      | VG    | 0.1212 | 0.3808 | 0.058  | 0.2127 | 0.205  | 0.0006 | 0.03   | 0.0472 | 0.7058 |
| 2020 | FG    | 0.1598 | 0.1523 | 0.0616 | 0.0143 | 0.0636 | 0.0922 | 0.0657 | 0.1395 | 0.1954 |
|      | MF    | 0.2622 | 0.2223 | 0.9235 | 0.1208 | 0.6987 | 0.0087 | 0.0004 | 0.1837 | 0.2075 |
|      | AP    | 0.4514 | 0.3866 | 0.181  | 0.7957 | 0.013  | 0.8716 | 0.0446 | 0.1464 | 0.0313 |
|      | VG    | 0.252  | 0.2564 | 0.0624 | 0.0521 | 0.113  | 0.0603 | 0.0705 | 0.0267 | 0.0565 |
| 2021 | FG    | 0.1352 | 0.0005 | 0.078  | 0.0857 | 0.0982 | 0.9852 | 0.2969 | 0.0856 | 0.0981 |
|      | MF    | 0.0006 | 0.1139 | 0.1236 | 0.1361 | 0.0924 | 0.1367 | 0.4258 | 0.0007 | 0.0078 |
|      | AP    | 0.1706 | 0.1977 | 0.8446 | 0.9849 | 0.8475 | 0.0741 | 0.0324 | 0.0921 | 0.1801 |
|      | VG    | 0.0594 | 0.1566 | 0.0008 | 0.0036 | 0.0024 | 0.0043 | 0.0004 | 0.0746 | 0.0001 |


Fonte: Elaborado pelo autor.

A discrepância nos valores médios de variância para os atributos ópticos é consideravelmente pequena em todos os atributos. Com base na Figura 34, tem-se que esses valores variaram entre 0 e 0,008. Possivelmente, devido a pequena amplitude dos valores de discrepância, observou-se que poucos atributos apresentaram significância estatística. Entre os atributos nos quais a variância mostrou potencial em discriminar entre áreas sadias e infestadas,

têm-se o SWIR 1 na fase AP em 2018 ( $p$ -valor: 0,0222), 2020 ( $p$ -valor: 0,0446) e 2021 ( $p$ -valor: 0,0324).

A Figura 35 apresenta as discrepâncias dos valores médios calculados a partir de séries temporais dos atributos SAR, enquanto a Tabela 12 apresenta os resultados do teste MWW considerando tais atributos.

**Figura 35** - Diferença nos valores de média dos atributos SAR de talhões sadios e infestados por nematóides. Devido os atributos possuírem diferentes intervalos de valores, eles são apresentados em: (a) discrepâncias para os atributos  $\sigma^0VV$ ,  $\sigma^0VH$ , sumV<sub>VVH</sub>, subV<sub>VVH</sub> e (b) discrepâncias para os atributos ratioV<sub>VVH</sub> e RVI. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa.



Fonte: Elaborado pelo autor.

**Tabela 12** - P-valor obtido a partir do teste MWW indicando a significância das diferenças dos atributos SAR (média). FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao  $p$ -valor  $\leq 0,05$ .

|      | Fases | $\sigma^0VV$ | $\sigma^0VH$ | sumV <sub>VVH</sub> | subV <sub>VVH</sub> | ratioV <sub>VVH</sub> | RVI    |
|------|-------|--------------|--------------|---------------------|---------------------|-----------------------|--------|
| 2017 | FG    | 0.0273       | 0.7343       | 0.164               | 0.0039              | 0.0039                | 0.0039 |
|      | MF    | 0.0976       | 0.4257       | 0.496               | 0.0039              | 0.039                 | 0.0039 |
|      | AP    | 0.0312       | 0.0625       | 0.0312              | 0.5625              | 0.1562                | 0.8437 |

**Tabela 12** - P-valor obtido a partir do teste MWW indicando a significância das diferenças dos atributos SAR (média). FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao p-valor  $\leq 0,05$ .

|      | Fases | $\sigma^0VV$ | $\sigma^0VH$ | sumVVVH | subVVVH | ratioVVVH | RVI    |
|------|-------|--------------|--------------|---------|---------|-----------|--------|
| 2018 | VG    | 0.0014       | 0.0009       | 0.0009  | 0.0048  | 0.0014    | 0.0048 |
|      | FG    | 0.0117       | 0.0117       | 0.0117  | 0.6523  | 0.0546    | 0.7343 |
|      | MF    | 0.039        | 0.0546       | 0.039   | 1       | 0.1289    | 0.7343 |
|      | AP    | 0.0312       | 0.0312       | 0.0312  | 0.4375  | 0.0312    | 0.4375 |
|      | VG    | 0.0004       | 0.0004       | 0.0004  | 0.0009  | 0.0004    | 0.0009 |
| 2019 | FG    | 0.0039       | 0.0039       | 0.0039  | 0.0273  | 0.0039    | 0.039  |
|      | MF    | 0.0039       | 0.0039       | 0.0039  | 0.0195  | 0.0039    | 0.9101 |
|      | AP    | 0.0312       | 0.0312       | 0.0312  | 0.0625  | 0.0312    | 0.1562 |
|      | VG    | 0.0004       | 0.0004       | 0.0004  | 0.0424  | 0.0004    | 0.0522 |
| 2020 | FG    | 0.0078       | 0.0078       | 0.0078  | 0.3007  | 0.0273    | 0.3593 |
|      | MF    | 0.0039       | 0.0039       | 0.0039  | 0.4257  | 0.0039    | 0.9101 |
|      | AP    | 0.0312       | 0.0312       | 0.0312  | 0.0625  | 0.0312    | 0.0625 |
|      | VG    | 0.0004       | 0.0004       | 0.0004  | 0.0004  | 0.0004    | 0.0004 |
| 2021 | FG    | 0.0039       | 0.0039       | 0.0039  | 0.3593  | 0.0039    | 0.3593 |
|      | MF    | 0.0039       | 0.0039       | 0.0039  | 0.0078  | 0.0039    | 0.0117 |
|      | AP    | 0.0312       | 0.0312       | 0.0312  | 0.0312  | 0.0312    | 0.0312 |
|      | VG    | 0.0004       | 0.0004       | 0.0004  | 0.0004  | 0.0004    | 0.0004 |


Fonte: Elaborado pelo autor.

De acordo com a Figura 35, o atributo sumVVVH foi o que apresentou os maiores valores de discrepância. Esse comportamento é esperado, haja vista que esse atributo é a soma das contribuições dos atributos  $\sigma^0VV$  e  $\sigma^0VH$ . Em relação às polarizações, as discrepâncias entre as classes foram maiores na polarização  $\sigma^0VV$  do que na polarização  $\sigma^0VH$  em todas as fases fenológicas, exceto na fase de maturação dos frutos em 2018. Em relação aos atributos da Figura 35b, tem-se o atributo RVI com as maiores discrepâncias, especialmente durante a fase VG. Esse comportamento é perceptível na Tabela 12, na qual durante a fase VG o atributo RVI apresentou p-valor inferior a 0,05 em todos os anos analisados, exceto em 2019.

Sintetizando os resultados indicados na Tabela 12, tem-se o atributo  $\sigma^0VV$  apresentando valores estatisticamente significativos em todas as fases fenológicas, exceto MF em 2018. Outros atributos como  $\sigma^0VH$ , sumVVVH, subVVVH e ratioVVVH demonstraram potencial em discriminar áreas sadias e infestadas na VG durante todo o período analisado. O atributo ratioVVVH também demonstrou contribuição durante a fase FG, exceto em 2018.

A Figura 36 apresenta as discrepâncias dos valores de variância calculados a partir de séries temporais dos atributos SAR, enquanto a Tabela 13 apresenta os resultados do teste Lavene considerando tais atributos.

**Figura 36** - Diferença nos valores de variância dos atributos SAR de talhões sadios e infestados por nematoides. Devido os atributos possuírem diferentes intervalos de valores, eles são apresentados em: (a) discrepâncias para os atributos  $\sigma^0VV$ ,  $\sigma^0VH$ , sumVVVH, subVVVH e (b) discrepâncias para os atributos ratioVVVH e RVI. FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa.



Fonte: Elaborado pelo autor.

**Tabela 13** - P-valor obtido a partir do teste Lavene indicando a significância das diferenças dos atributos SAR (variância). FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao p-valor  $\leq 0,05$ .

|      | Fases | $\sigma^0VV$ | $\sigma^0VH$ | sumVVVH | subVVVH | ratioVVVH | RVI    |
|------|-------|--------------|--------------|---------|---------|-----------|--------|
| 2017 | FG    | 0.3515       | 0.4394       | 0.3149  | 0.1879  | 0.1981    | 0.1783 |
|      | MF    | 0.0914       | 0.1553       | 0.0635  | 0.5469  | 0.907     | 0.6215 |
|      | AP    | 0.067        | 0.2112       | 0.0408  | 0.4094  | 0.3381    | 0.2561 |
|      | VG    | 0.4188       | 0.3693       | 0.6807  | 0.1154  | 0.8902    | 0.2697 |
| 2018 | FG    | 0.1213       | 0.2898       | 0.0879  | 0.4187  | 0.8416    | 0.6258 |
|      | MF    | 0.4136       | 0.3614       | 0.4386  | 0.9068  | 0.0403    | 0.0914 |
|      | AP    | 0.4268       | 0.5143       | 0.3858  | 0.7258  | 0.2711    | 0.9294 |
|      | VG    | 0.4629       | 0.0149       | 0.4083  | 0.2959  | 0.4527    | 0.3261 |
| 2019 | FG    | 0.6309       | 0.9036       | 0.9509  | 0.1771  | 0.0359    | 0.17   |
|      | MF    | 0.8831       | 0.4965       | 0.4608  | 0.9187  | 0.7793    | 0.5621 |
|      | AP    | 0.7411       | 0.331        | 0.407   | 0.3588  | 0.1236    | 0.9664 |

**Tabela 13** - P-valor obtido a partir do teste Lavene indicando a significância das diferenças dos atributos SAR (variância). FG é a fase de formação dos grãos, MF é a fase de maturação dos frutos, AP é a fase de autopoda e VG é a fase vegetativa. Os valores destacados em vermelho referem-se ao  $p\text{-valor} \leq 0,05$ .

|      | Fases | $\sigma^0VV$ | $\sigma^0VH$ | sumVVVH | subVVVH | ratioVVVH | RVI    |
|------|-------|--------------|--------------|---------|---------|-----------|--------|
| 2020 | VG    | 0.4863       | 0.0105       | 0.1339  | 0.244   | 0.5612    | 0.1469 |
|      | FG    | 0.6794       | 0.6388       | 0.974   | 0.3935  | 0.2032    | 0.3751 |
|      | MF    | 0.5936       | 0.8486       | 0.6994  | 0.5098  | 0.227     | 0.2727 |
|      | AP    | 0.045        | 0.9087       | 0.1242  | 0.3811  | 0.0146    | 0.5215 |
|      | VG    | 0.3334       | 0.901        | 0.9975  | 0.5534  | 0.0733    | 0.1827 |
| 2021 | FG    | 0.2578       | 0.2583       | 0.2582  | 0.6487  | 0.6652    | 0.3258 |
|      | MF    | 0.0597       | 0.082        | 0.0887  | 0.2695  | 0.2665    | 0.3908 |
|      | AP    | 0.0953       | 0.0282       | 0.0194  | 0.3486  | 0.2636    | 0.9918 |
|      | VG    | 0.0004       | 0.0004       | 0.0004  | 0.0004  | 0.0004    | 0.0004 |


Fonte: Elaborado pelo autor.

Os resultados apresentados na Figura 36 deixam claro que as discrepâncias da variância entre talhões sadios e infestados foram maiores para  $\sigma^0VV$  do que para  $\sigma^0VH$ . Apesar disso, a partir do teste de Lavene, nenhuma diferença significativa foi encontrada para a maioria dos atributos SAR. Exceto o atributo  $\sigma^0VH$  que demonstrou significância estatística na fase VG em 2018 ( $p\text{-valor} = 0.0149$ ), 2019 ( $p\text{-valor} = 0.0105$ ) e 2021 ( $p\text{-valor} = 0.0004$ ). A baixa separabilidade entre áreas sadias e infestadas a partir da variância pode ser decorrente do processamento de redução do speckle, o qual tende a reduzir a variância das intensidades dos pixels.

#### 4.1.3.3 Importância dos atributos ópticos e SAR para discriminação de áreas infestadas por nematoides na cultura cafeeira

Antes de apresentar os resultados da seleção de atributos, a partir da abordagem SHAP, é importante destacar que os resultados apresentados nesta seção podem diferir dos resultados apresentados na Seção 4.1.3.2, uma vez que a falta de significância estatística não significa, necessariamente, ausência de efeito de um determinado atributo. Diante disso, é necessário a utilização de métodos que descrevam o efeito de cada variável no fenômeno estudado. Para isso, os métodos de seleção de atributos é uma alternativa interessante, uma vez que esses métodos procuram preservar os atributos que retém informações relevantes sobre o objeto de estudo. Assim sendo, a Figura 37 e Figura 38 mostram os resultados da seleção de atributos ópticos e SAR, respectivamente, com base nas fases fenológicas. Os polígonos coloridos denotam as fases fenológicas: os polígonos bege, laranja, marrom e verde indicam as fases de formação dos grãos (FG), maturação dos frutos (MF), autopoda (AP) e vegetativa (VG), respectivamente.

**Figura 37** - Importância dos atributos ópticos em discriminar entre talhões saudios e infestados por fase fenológica: (a) formação dos grãos, (b) maturação dos frutos, (c) autopoda, e (d) vegetativo. As letras m e v se referem a média e a variância, respectivamente.



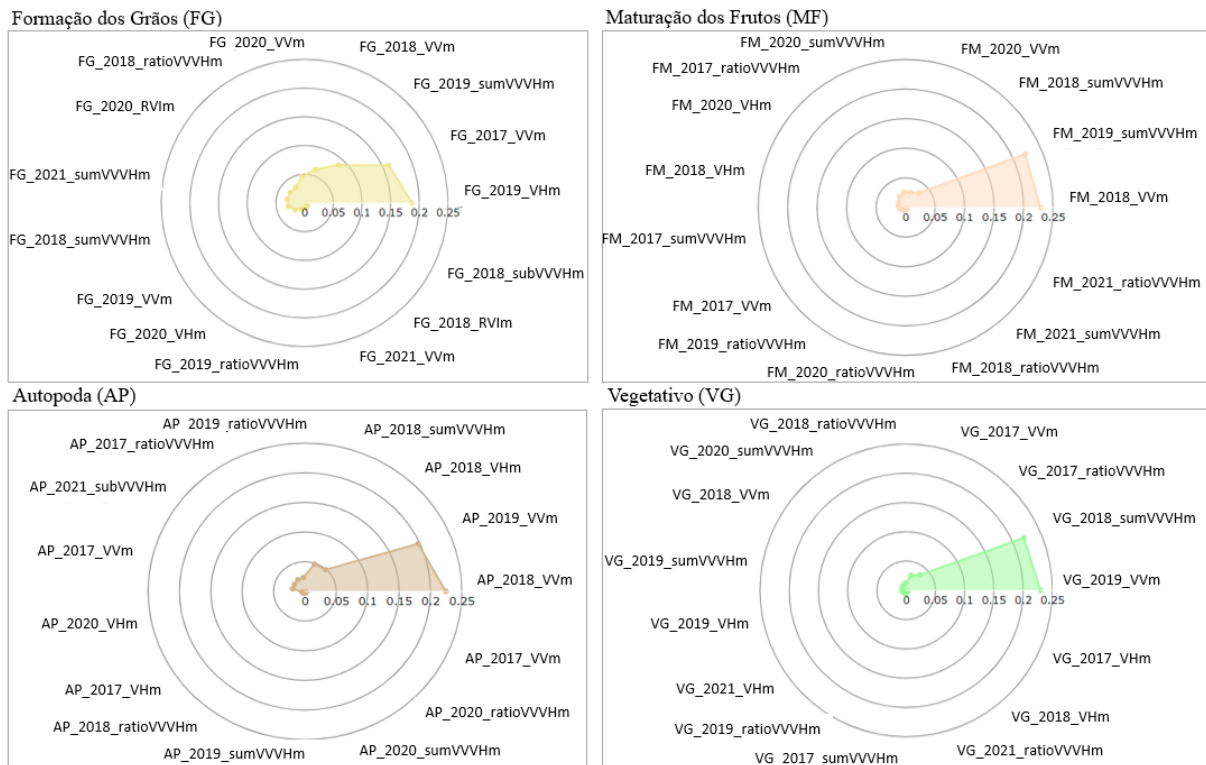
Fonte: Elaborado pelo autor.

A partir da Figura 37, é possível observar a predominância dos atributos B6 (*red-edge* 1), B7 (*red-edge* 2), B11 (SWIR 1) e B12 (SWIR 2) como os mais relevantes em discriminar entre áreas saudias e infestadas por nematoides. Na fase FG, a variância dos atributos B12 e B11 em 2019 aparecem como os de maior importância, respectivamente. Além disso, a média do atributo B7 apresentou maior contribuição nas fases MF e AP. Por fim, na fase VG, a média do atributo B12 e a variância de B6 aparecem como os atributos com maiores valores SHAP.

Ao analisar os anos correspondentes aos atributos que tiveram maiores valores de importância, observou-se que os atributos são na sua maioria os anos de 2017 e 2019. Esse resultado é condizente com os resultados apresentados na Tabela 10. Em contrapartida, para a variância dos atributos não foi encontrado similaridade com os resultados apresentados na Tabela 11. Por fim, considerando a magnitude dos valores de importância dos atributos mais relevantes em cada fase fenológica, verifica-se que foram nas fases MF e AP que se obteve os maiores valores SHAP.

Na Figura 38 são apresentados os atributos SAR mais importantes de acordo com cada fase fenológica

**Figura 38** - Importância dos atributos SAR em discriminar entre talhões saudios e infestados por fase fenológica: (a) formação dos grãos, (b) maturação dos frutos, (c) autopoda, e (d) vegetativo. As letras m e v se referem a média e v a variância.



Fonte: Elaborado pelo autor.

Os resultados apresentados na Figura 38 se mostraram condizentes com os resultados da Tabela 12 e Tabela 13, evidenciando a maior contribuição da métrica média do que da variância. Além disso, os resultados deixam claro a MF e AP que se obteve os maiores valores SHAP em relação aos demais atributos. Dentre as quatro fases fenológicas avaliadas,  $\sigma^0VV$  aparece como o atributo mais importante em MF, AP e VG. Tendo em vista a magnitude dos valores de importância, ambas as fases apresentaram valores similares de importância, exceto a fase FG que apresentou valores SHAP inferiores a 0,2.

#### 4.1.4 Potencial de séries temporais de atributos ópticos e SAR na detecção de nematoides no cafeeiro

Este experimento procurou atender os seguintes objetivos desta tese: caracterizar os padrões fenológicos do cafeeiro sadio e infestado por nematoides a partir de séries temporais de atributos ópticos e SAR; avaliar a contribuição de atributos extraídos das séries temporais de atributos ópticos e SAR na detecção de nematoides, bem como identificar as fases fenológicas que favoreçam essa discriminação. Esses objetivos buscam propor alternativas às limitações relacionadas com a disponibilidade de dados em regiões com alta cobertura de

---

nuvens, como é o caso do Cerrado Mineiro, e identificação de variáveis e períodos que contribuam efetivamente para a detecção do patógeno. É importante destacar que este último ponto é fortemente relacionado com a disponibilidade de dados, principalmente quando se trata de dados no domínio óptico. Diante disso, propôs-se a utilização de dados no espectro micro-ondas, além de uma investigação no domínio temporal.

Assim sendo, a partir dos perfis temporais de cada atributo (ópticos e SAR) foi possível identificar que há períodos em que a separabilidade entre áreas saudas e infestadas é mais evidente (Seção 4.1.3.1). As análises da Seção 4.1.3.2 permitiram confirmar se as discrepâncias verificadas nos perfis temporais de áreas saudas e infestadas são significativas estatisticamente. E por fim, a partir da Seção 4.1.3.3 foi possível identificar os atributos e fases fenológicas que favorecem a detecção de nematoides na cultura cafeeira. Os resultados mostraram que:

- Atributos derivados de dados Sentinel-1 e Sentinel-2 podem fornecer informações importantes sobre o comportamento sazonal de áreas saudas e infestadas por nematoides. É que é perceptível a alteração da resposta espectral/retroespalhamento do cafeeiro infestado por nematoides;
- Os atributos ópticos na região do *red-edge* e SWIR (B11 e B12) são capazes de discriminar áreas infestadas por nematoides. Em Chemura *et al.* (2017), os autores identificaram que a região do *red-edge* é relevante para a discriminação da ferrugem do café. Os resultados apresentados nesta pesquisa sugerem que esses atributos também são relevantes para a detecção de nematoides.
- Quanto a utilização das métricas média e variância para caracterização de áreas saudas e infestadas, os resultados não foram satisfatórios para utilização da variância, tanto para os atributos ópticos quanto para os atributos SAR.
- Além disso, foi confirmada a contribuição da polarização  $\sigma^0_{VV}$  na detecção de nematoides. Este resultado permite que sejam geradas séries temporais mais densas e, conseqüentemente, a utilização de atributos complementares para melhorar as estratégias de monitoramento e gerenciamento de nematoides na cultura cafeeira.
- Além dos atributos mais relevantes, a análise de importância dos atributos ópticos indica as fases de maturação dos frutos e autopoda como as mais apropriadas na discriminação de áreas saudas e infestadas a partir do atributo B7 (*red-edge 3*). Para as fases de formação dos grãos e vegetativa o atributo B12 (SWIR2) foi o que apresentou os maiores valores SHAP. Para os atributos SAR,

---

os resultados fornecem evidências para o uso de  $\sigma^0VV$  em todas as fases fenológicas, exceto na fase de formação de grãos.

## 4.2 Experimento 2: Detecção de áreas de infestação por nematoides por meio de rede BiLSTM

### 4.2.1 Contextualização

Na Seção 4.1 foram realizadas análises visuais e estatísticas sobre os atributos extraídos de séries temporais de imagens Sentinel-1 e Sentinel-2, bem como a análise de importância desses atributos, visando a determinação de atributos e fases fenológicas mais propícias para a detecção de nematoides. Ainda que os atributos tenham sido extraídos de séries temporais, cabe ressaltar que, naquele contexto, não foram consideradas as dependências temporais, ou seja, não se explorou o efeito das variações sazonais ao longo de toda ou parte da série temporal.

Dados no domínio temporal podem fornecer informações relevantes no que diz respeito ao comportamento da cultura agrícola ao longo do seu ciclo de desenvolvimento. Essa constatação é corroborada por Arvor *et al.* (2011), ao destacarem que séries temporais de índices de vegetação permitem o monitoramento da fenologia e das variações intrasazonais das áreas agrícolas. Além disso, a depender da complexidade do problema, dados de sensoriamento remoto a partir de uma única data podem não ser suficientes para atingir resultados com a precisão necessária (DEBELLA-GILO e GJERTSEN, 2021). Nesse sentido, Chen *et al.* (2022) afirmam que a variabilidade intraclasse e a similaridade entre classes não podem não ser capturadas usando apenas imagens de uma única data.

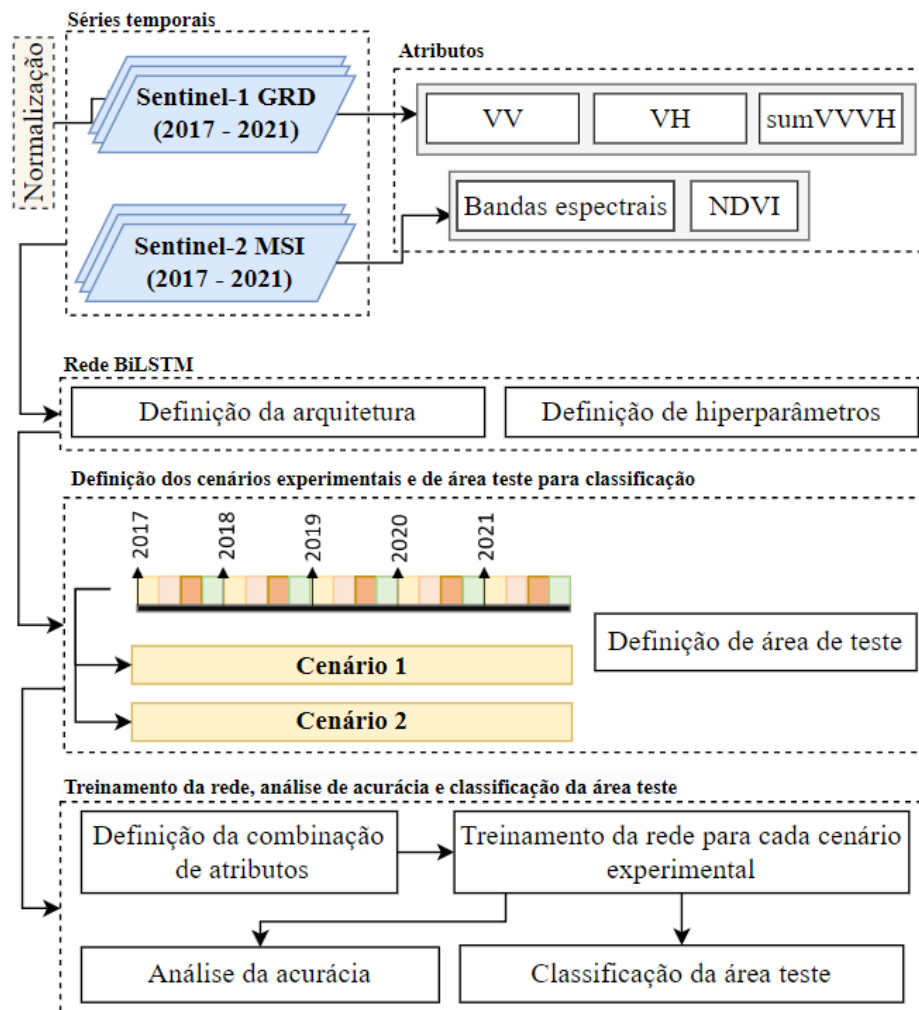
Algoritmos baseados em aprendizado profundo têm alcançado bons resultados para detecção de mudanças, mapeamento do uso e cobertura da terra, identificação e monitoramento de culturas agrícolas (ALI e JOHNSON, 2022; CHERIF; HELL; BRANDMEIER, 2022; PIERRE POTT *et al.*, 2022; SREEDHAR; VARSHNEY; DHANYA, 2022). Em estudos agrícolas, o uso combinado de séries temporais de dados ópticos e SAR podem fornecer informações importantes quanto aos padrões sazonais de culturas agrícolas (WANG *et al.*, 2022). Trabalhos como o de Castro Filho *et al.* (2020) mostram ótimos resultados por meio da exploração de redes neurais recorrentes (RNN) para análise das variações sazonais em culturas agrícolas. Dentre as estruturas de RNN, as redes *Long Short Term Memory* (LSTM) vêm ganhando destaque por superarem o problema de desaparecimento de gradiente, comum nas RNN, e por capturarem dependências de longo prazo em séries temporais. Além das redes LSTM unidirecionais, existem também as redes bidirecionais, as quais possibilitam o processamento de dados nas direções *forward* e *backward*, alcançando resultados superiores às redes LSTM na classificação de culturas agrícolas (CHEN *et al.*, 2022).

Diante disso, neste experimento procura-se atender ao seguinte objetivo desta tese: avaliar a capacidade de redes BiLSTM na detecção de nematoides em áreas de cultivo de cafeeiro. Concomitantemente a isso, pretende-se verificar a contribuição de diferentes cenários de construção de séries temporais para esse propósito.

#### 4.2.2 Metodologia

O fluxograma da Figura 39 apresenta a metodologia adotada na detecção espaço-temporal de nematoides utilizando redes BiLSTM. Os dados utilizados nessa etapa referem-se aos atributos ópticos e SAR, apresentados na Seção 3.2.2. Esses dados foram aplicados a uma rede BiLSTM para definição dos hiperparâmetros (Seção 4.2.2.1). Posteriormente, essa rede foi utilizada no treinamento de diversas combinações de atributos de acordo com cada cenário experimental (Seções 4.2.2.2 e 4.2.2.3). Por fim, cada treinamento foi analisado a partir das métricas de acurácia descritas na Seção 4.2.2.4.

**Figura 39** - Fluxograma utilizado para aplicação de redes BiLSTM para detecção de nematoides




Fonte: Elaborado pelo autor.

#### 4.2.2.1 Arquitetura da rede BiLSTM e especificação dos hiperparâmetros

Uma rede LSTM bidirecional (BiLSTM) foi utilizada nesta pesquisa com o objetivo de detectar áreas que apresentam características de infestação por nematoides, a partir de séries temporais de atributos ópticos e SAR. A rede BiLSTM foi escolhida por capturar melhor as características temporais dos dados devido à sua capacidade de aprendizagem em duas direções. Esse tipo de rede, de modo geral, possui duas camadas LSTM, treinadas simultaneamente, sendo que cada uma trabalha em uma direção diferente (*forward* e *backward*) da sequência dos dados de entrada. Especificamente, uma rede processa os estados passados, e a outra com os estados futuros (GRAVES, 2012b; SCHUSTER e PALIWAL, 1997).

Como mostra a Figura 40, as entradas ( $x$ ) são aplicadas em uma rede bidirecional (LSTM e LSTM'), na qual uma camada analisa os dados de entrada no sentido *forward*, e a outra com os dados de entrada lidos no sentido *backward*. As saídas ( $y$ ) da rede resultam da concatenação dos resultados das duas direções. Cabe destacar que neste modelo, a saída dos neurônios na direção *forward* é independente daquela na direção *backward*, conforme as Equações 22, 23 e 24. Dessa forma, uma rede bidirecional possui maior capacidade de compreender o contexto temporal dos dados (GRAVES, 2012a; YIN *et al.*, 2021).

Figura 40 - Representação de uma rede BiLSTM.



Fonte: Adaptado de Tyagi e Abraham (2023).

$$\vec{a}^{(t)} = \varphi_1(W_{\vec{a}}[x^{(t)}; a^{(t-1)}] + b_{\vec{a}}) \quad (22)$$

$$\tilde{a}^{(t)} = \varphi_2(W_{\tilde{a}}[x^{(t)}; a^{(t+1)}] + b_{\tilde{a}}) \quad (23)$$

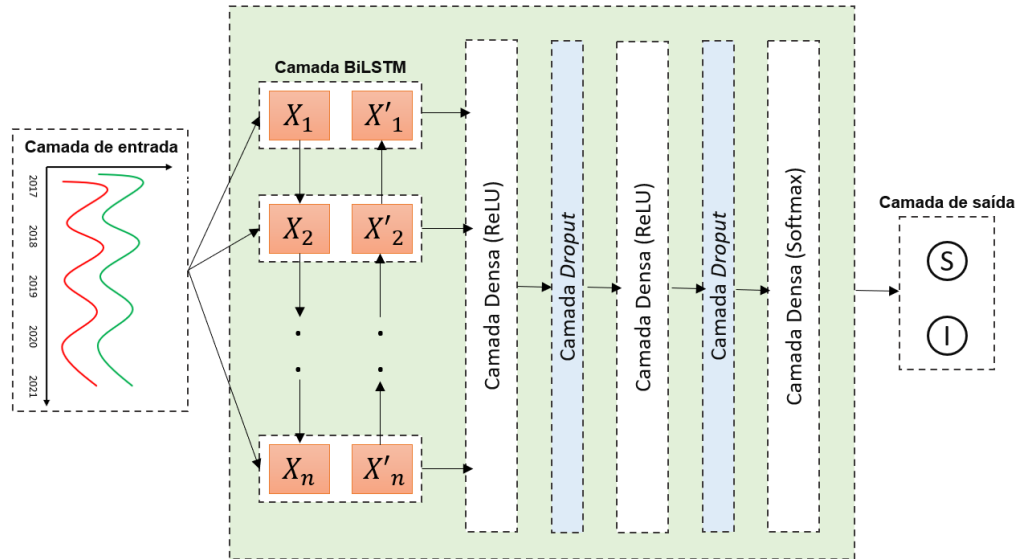
$$\hat{y}^{(t)} = \varphi_2(W_y[\vec{a}^{(t)}; \tilde{a}^{(t)}] + b_y) \quad (24)$$

sendo que  $\varphi$  representa a função de ativação,  $b$  é um *offset*,  $W$  representa os pesos,  $t$  é o tempo,  $\hat{y}$  é a saída do modelo,  $\vec{a}^{(t)}$  e  $\tilde{a}^{(t)}$  são as saídas das direções *forward* e *backward*, respectivamente.

A arquitetura de rede BiLSTM utilizada nesta pesquisa é apresentada na Figura 41, a qual foi implementada a partir das bibliotecas *Tensorflow* e *Keras*, disponíveis em *Python*. Tais

bibliotecas são de código aberto e foram criadas para facilitar os processos de construção e treinamento de redes neurais.

**Figura 41** - Arquitetura de rede BiLSTM utilizada.



Fonte: Elaborado pelo autor.

A arquitetura da rede neural, apresentada na Figura 41, consiste em uma camada BiLSTM, três camadas densas (*fully connected*) e duas camadas *dropout*. Nas duas primeiras camadas densas, foi utilizada a função de ativação *Rectified Linear Unit* (ReLU) e na camada de classificação foi adotada a função *Softmax*, essa última adequada aos problemas de classificação, uma vez que permite inferir a probabilidade de uma instância pertencer a uma determinada classe. Entre cada camada densa, foi inserida uma camada *dropout*. O *dropout* é uma função de regularização, proposta por Hinton *et al.* (2012), para evitar *overfitting* durante o treinamento. Basicamente, essa função ignora randomicamente alguns neurônios durante o processo de aprendizagem com base em um percentual pré-determinado.

A configuração dos hiperparâmetros em redes neurais afeta o desempenho do algoritmo (YANG *et al.*, 2020). Diante disso, com o objetivo de selecionar a melhor configuração de valores para os hiperparâmetros, foram testadas empiricamente diversas configurações para os hiperparâmetros: épocas de treinamento, taxa de aprendizagem, *batch size*, otimizador, função de perda e quantidade de neurônios nas camadas escondidas. Dos hiperparâmetros testados, o otimizador *Adaptive Moment Optimization* (*Adam*) e as funções de ativação (*Relu*, *Softmax*) foram mantidas constantes em todos os testes. Com base nos resultados experimentais, os valores que apresentaram melhor desempenho estão descritos na Tabela 14.

**Tabela 14** - Hiperparâmetros utilizados na rede BiLSTM.

| Hiperparâmetros                  | Valores  |
|----------------------------------|--|
| Função de perda                  | <i>SparseCategoricalFocalLoss</i> ( $\gamma=2$ ) |
| Otimizador                       | <i>Adam</i>                                      |
| Épocas                           | 100  |
| <i>Dropout</i>                   | 0,1  |
| Taxa de aprendizagem             | 0,001  |
| <i>Batch size</i>                | 16   |
| Camadas escondidas               | 4  |
| Neurônios nas camadas escondidas | (32,16,8,3)                                      |
| Função                           | <i>Relu, Softmax</i>                             |

Fonte: Elaborado pelo autor.

Dentre os hiperparâmetros definidos, a função de perda utilizada, devido ao desbalanceamento dos dados de treinamento, foi a *SparseCategoricalFocalLoss* (Equação 25). Esse tipo de função pondera a contribuição de cada amostra no valor de perda com base no erro de classificação. Isso permite que a função produza um valor de perda baixo para instâncias bem classificadas ( $\hat{y}_i > 0,5$ ), mas uma perda alta para aqueles mais difíceis de se classificar (LIN *et al.*, 2020).

$$FL = - \sum_{i=1}^M y_i (1 - \hat{y}_i)^\gamma \log(\hat{y}_i), \gamma \geq 0 \quad (25)$$

$y_i$  são as classes,  $\hat{y}_i$  é a probabilidade de um valor predito pertencer a determinada classe,  $\gamma$  é o parâmetro de foco (*focusing parameter*) e  $(1 - \hat{y}_i)^\gamma$  é o fator de modulação. O parâmetro de foco ( $\gamma$ ) ajusta a taxa na qual o fator de modulação  $(1 - \hat{y}_i)^\gamma$  afeta a perda, portanto, valores mais altos de  $\gamma$  aumentam a importância de corrigir exemplos mal classificados.

O otimizador *Adam* é utilizado para ajustar automaticamente os pesos e a taxa de aprendizado da rede (KINGMA e BA, 2017). Além disso, foi utilizado o parâmetro *early stopping*. O principal objetivo desse parâmetro é evitar *overfitting* a partir da parada antecipada do treinamento. Para isso, é determinada uma métrica para análise da parada e uma janela de tolerância (*patience*). Nesse caso, foi utilizada a métrica *validation loss* e a janela de tolerância de 5 épocas, ou seja, caso a métrica *validation loss* não seja alterada em até 5 épocas consecutivas, o treinamento é encerrado.

Por fim, é importante destacar que devido ao desbalanceamento dos dados de treinamento e por se tratar de um problema de classificação binária, optou-se pela proposição de um modelo de rede de menor complexidade, visando evitar *overfitting*. Para isso, foram adotadas algumas estratégias, sendo elas: menor número de neurônios nas camadas da rede,

camadas *dropout* entre as camadas densas, critério de parada antecipada e uma função de perda apropriada para lidar com conjuntos de dados desbalanceados.

#### 4.2.2.2 Especificação dos dados de treinamento e das combinações de atributos de entrada da rede BiLSTM

Os dados de treinamento foram adquiridos a partir dos valores dos pixels contidos em cada uma das áreas de referência (descritas na Seção 3.1.2 e Figura 22), totalizando 3628 pixels da classe cafeeiro infestado e 10948 pixels da classe cafeeiro sadio. Ou seja, para cada pixel, rotulado como sadio ou infestado, foram geradas séries temporais com 60 observações de tempo (dados mensais). É importante notar que ocorre um desbalanceamento entre as classes, e que apesar disso foram adotadas estratégias que visam minimizar os efeitos desse desbalanceamento, conforme apresentado na Seção 4.2.2.1.

Li; Tian; Tian (2023) afirmam que a classificação de culturas agrícolas a partir de imagens multitemporais é dependente de diversos fatores, dentre eles a construção das séries temporais, a seleção de atributos e o método de classificação. Diante disso, diferentes combinações de atributos foram aplicadas a uma rede BiLSTM com o intuito de identificar a combinação de atributos que forneça a maior acurácia na discriminação das áreas sadias e infestadas. Os experimentos foram realizados considerando atributos ópticos, SAR e a combinação destes (ópticos + SAR) (Tabela 15).

**Tabela 15** - Combinação de atributos utilizados no treinamento da rede BiLSTM.

| Dados         | Atributos          | Descrição dos atributos                             |
|---------------|--------------------|---|
| Ópticos       | VIS                | B3, B4  |
|               | VIS + NIR          | B3, B4, B8  |
|               | VIS + RED*         | B3, B4 + RED (B5, B6, B7, B8A)                      |
|               | VIS + SWIR*        | B3, B4 + SWIR (B11, B12)                            |
|               | VIS + NDVI         | B3, B4, NDVI  |
| SAR           | $\sigma^0$ VV      | Polarização vertical                                |
|               | $\sigma^0$ VH      | Polarização horizontal                              |
|               | sumVVVH            | Soma das polarizações $\sigma^0$ VV e $\sigma^0$ VH |
| Ópticos + SAR | VIS + SAR*         | B3, B4, cada atributo SAR                           |
|               | VIS + NIR + SAR*   | B3, B4, B8, cada atributo SAR                       |
|               | VIS + RED* + SAR*  | B3, B4 + RED (B5, B6, B7, B8A) + cada atributo SAR  |
|               | VIS + SWIR* + SAR* | B3, B4 + SWIR (B11, B12) + cada atributo SAR        |
|               | VIS + NDVI + SAR*  | B3, B4, NDVI, cada atributo da SAR                  |

\* Foi realizado um treinamento com cada atributo que compõe o conjunto de atributos

Fonte: Elaborado pelo autor.

É importante ressaltar que para aplicações que envolvam dados de diferentes escalas, é necessário transformar os valores dos atributos para um intervalo comum. Para os dados utilizados nesta tese, foi necessário a normalização dos dados SAR para compatibilizar suas magnitudes à dos dados

ópticos. Nesse sentido, todos os atributos SAR indicados na Tabela 15 foram normalizados para o intervalo [0,1].

#### 4.2.2.3 Métricas usadas na avaliação do treinamento da rede BiLSTM

Para todos os treinamentos realizados, o conjunto de dados de treinamento foi dividido de modo que 80% fossem utilizados para treinamento e 20% para teste. A análise do modelo após cada treinamento, considerando os diferentes cenários e combinações de atributos, foi realizada utilizando as métricas *recall* (Equação 26), *precision* (Equação 27), *F-score* (Equação 28). A métrica *precision* é utilizada para se obter a proporção de detecção correta para cada classe, a *recall* representa a proporção de predição correta diante de todos os casos reais de determinada classe, o *F-Score* é a média harmônica entre as métricas *precision* e *recall*.

|      |          | Predito  |          |
|------|----------|----------|----------|
|      |          | Positivo | Negativo |
| Real | Positivo | VP       | FN       |
|      | Negativo | FP       | VN       |

$$recall = \frac{VP}{VP+FN} \quad (26)$$

$$precision = \frac{VP}{VP+FP} \quad (27)$$

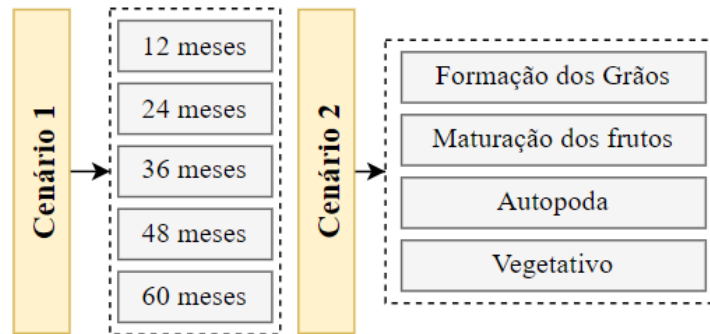
$$F-Score = 2 \times \frac{recall \times precision}{recall + precision} \quad (28)$$

*VP* (verdadeiro positivo) é o número de elementos identificados na classe de interesse coincidente com os dados de referência; *FP* (falso positivo) é o número de pixels identificados na classe de interesse que não são coincidentes com os dados de referência e *FN* é o número de elementos da outra classe que não são coincidentes com os dados de referência.

#### 4.2.2.4 Definição dos cenários experimentais e área teste

Neste trabalho, dois cenários experimentais (Figura 42) são propostos com os seguintes objetivos: (1) Cenário 1: Avaliar o impacto do tamanho da série temporal na discriminação de áreas sadias e infestadas por nematoides; (2) Cenário 2: Avaliar a capacidade de discriminação de áreas sadias e infestadas por nematoides em cada fase fenológica. Espera-se a partir desses cenários experimentais identificar o tamanho mínimo da série temporal capaz de produzir resultados satisfatórios, além da possibilidade de se obter resultados adequados somente a partir das informações de uma única fase fenológica.

**Figura 42** - Definição dos cenários experimentais.



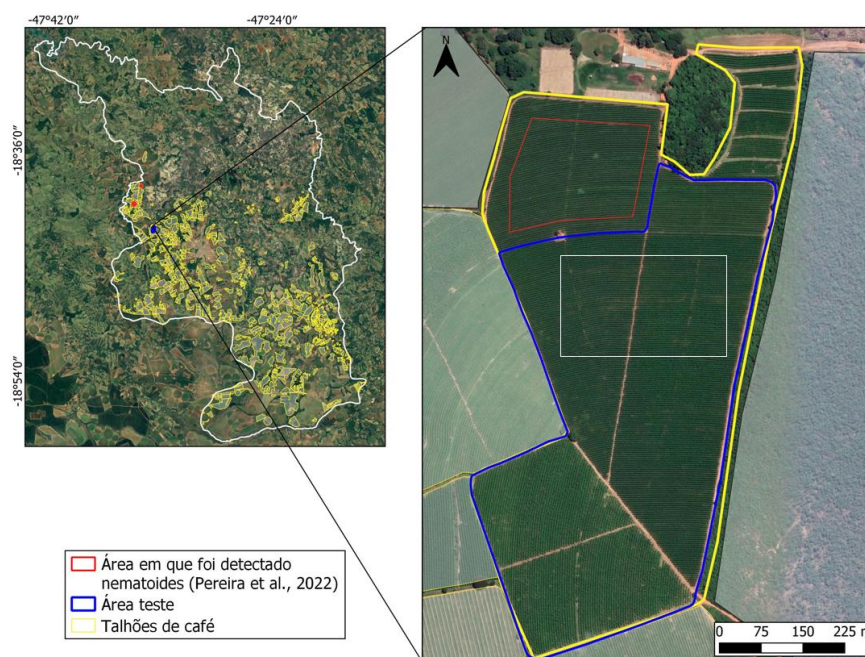
Fonte: Elaborado pelo autor.

No cenário 1, foram avaliados diferentes tamanhos das séries temporais, aumentando seu tamanho em 12 meses a cada treinamento (12 meses: 2017; 24 meses: 2017 e 2018; 36 meses: 2017 a 2019; 48 meses: 2017 a 2020 e; 60 meses: 2017 a 2021). Para isso, foram gerados gráficos da métrica *recall* das classes sadio e infestado, considerando as combinações de atributos ópticos e SAR, separadamente. Posteriormente, com o objetivo de avaliar a contribuição de atributos SAR, em discriminar áreas infestadas, foram gerados gráficos da métrica *recall* para a classe infestado.

No caso do cenário 2, o treinamento foi realizado considerando somente os meses que compõem cada fase fenológica, dentro dos 60 meses. Assim, para a fase de formação dos grãos foram utilizados os valores dos atributos dos meses de janeiro, fevereiro e março (15 observações), maturação dos frutos contempla os meses de abril, maio e junho (15 observações), autopoda ocorre em julho e agosto (10 observações) e a fase vegetativa se estende de setembro a dezembro (20 observações). Esse cenário também foi analisado a partir de gráficos da métrica *recall* considerando atributos ópticos e a integração de atributos ópticos e SAR. Cabe destacar que tanto no Cenário 1 quanto no Cenário 2, foi utilizada a métrica *recall* para composição dos gráficos pelo fato dessa métrica fornecer uma proporção de amostras classificadas corretamente pelo modelo, facilitando a análise da classe de interesse que corresponde a áreas infestadas por nematoides.

Além disso, para cada cenário experimental foram gerados mapas da distribuição espacial de potenciais áreas de infestação para cada combinação de atributos (ópticos, SAR ( $\sigma^0VV$  e  $\sigma^0VH$ ), ópticos + SAR). Para isso, foi selecionada uma área de cultivo de cafeeiro (Figura 43), dentre as áreas fornecidas pelo Instituto de Ciências Agrárias da Universidade Federal de Uberlândia. Essa área está localizada próxima ao polígono de referência I3 (Figura 22, Seção 3.1.2), no qual foi constatado a ocorrência de nematoides, conforme descrito por Pereira *et al.* (2022). A priori, é possível perceber que, principalmente na região central da área (polígono em branco), a densidade de plantas não é uniforme e que há padrões característicos de plantas em senescência, o que pode estar relacionado com a ocorrência de nematoides.

**Figura 43** - Área utilizada para aplicação da rede BiLSTM.



Fonte: Elaborado pelo autor.

### 4.2.3 Resultados e Discussão


Nesta seção serão apresentados os resultados obtidos a partir da aplicação da rede BiLSTM para discriminação de nematoides na cultura cafeeira. O Cenário 1 teve por objetivo a análise do desempenho do modelo considerando diferentes combinações de atributos e tamanhos de série temporal. No Cenário 2 foram avaliadas diferentes combinações de atributos para as 4 fases fenológicas do cafeeiro. Nesse experimento é analisado a possibilidade de se detectar áreas da infestação por nematoides utilizando apenas a informação de uma única fase fenológica. Em ambos os cenários foram testados o incremento de atributos SAR, visando a verificação da contribuição deste tipo de dado.

#### 4.2.3.1 Cenário 1: Impacto do tamanho da série temporal na discriminação de áreas infestadas por nematoides

A Figura 44 apresenta os resultados do Cenário 1, no qual foi analisado o impacto do tamanho da série temporal na discriminação de áreas infestadas por nematoides. Inicialmente, foi analisado os resultados obtidos a partir das combinações de atributos ópticos e SAR, separadamente. Para isso foram analisados os valores obtidos, no treinamento, a partir da métrica *recall*. A Figura 45 apresenta os resultados também do Cenário 1, porém, nesse momento, foi considerada a contribuição dos atributos SAR. Cabe destacar que na Figura 45 são apresentados os resultados tanto para a classe sadio quanto para a classe infestado.

Posteriormente, para análise da contribuição dos atributos SAR é apresentado somente os resultados obtidos para a classe infestado.

**Figura 44** - Valores obtidos para as métricas *recall* em função do tamanho da série temporal. As barras nas cores verde e laranja representam as classe sadio e infestado, respectivamente.



Fonte: Elaborado pelo autor.

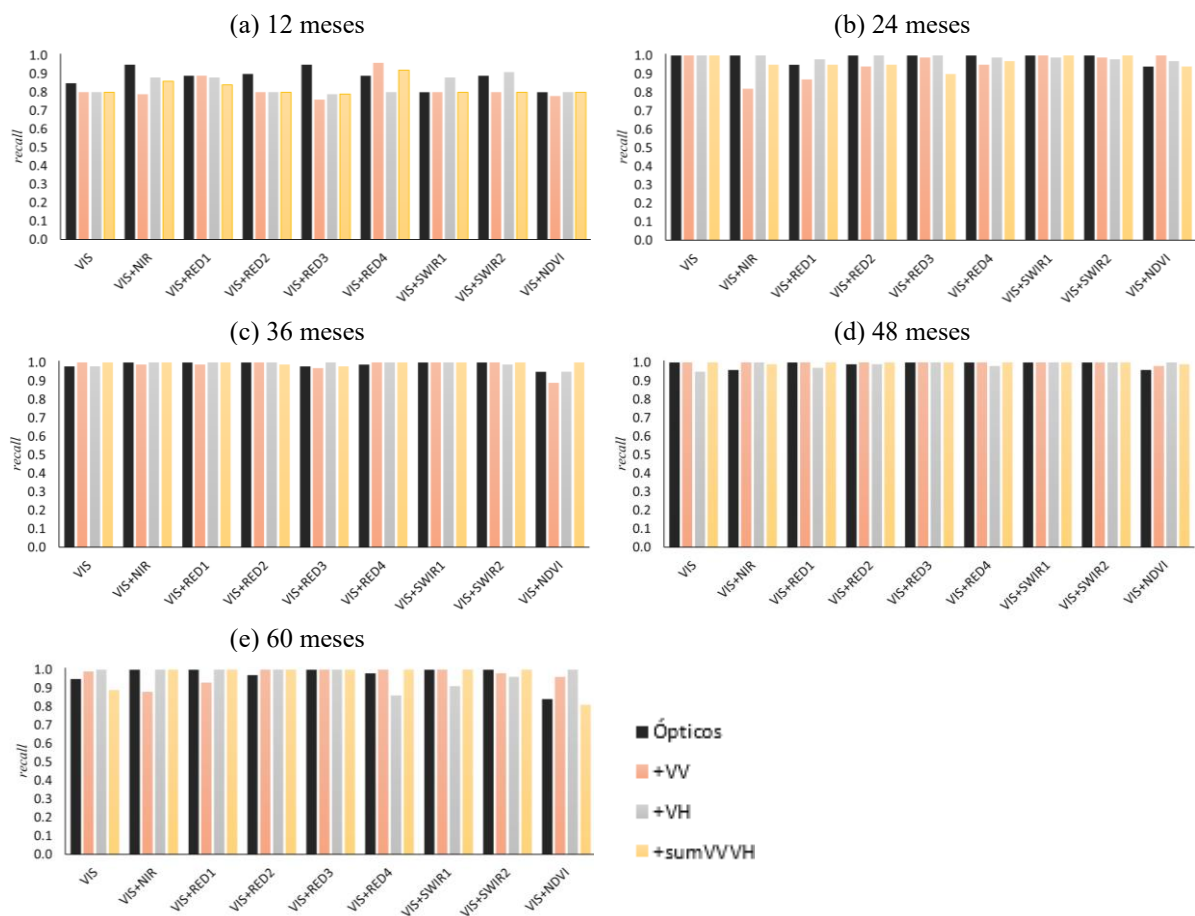
Pela Figura 44, verifica-se que os atributos ópticos são pouco afetados pelo tamanho da série temporal. Contudo, os valores de *recall* para a classe infestado, ao se utilizar apenas 1 ano de dados, são consideravelmente menores que ao se utilizar dois anos de dados. Em relação às combinações de atributos, têm-se que as VIS+SWIR1 e VIS+SWIR2 apresentaram *recall* igual a 1, para a classe infestado, para todos os comprimentos de série temporal, exceto para a de 12 meses (Figura 44a). Além disso, tem-se que a combinação VIS+NDVI foi a que apresentou os menores valores de *recall* em todos os períodos avaliados, sendo o pior resultado obtido a partir da série temporal de 12 meses.

Ao considerar apenas os atributos SAR, os valores de *recall* aumentaram de acordo com o tamanho da série temporal. Nesse sentido, observa-se que foi possível obter valores de *recall*

superiores a 0,80 a partir de 4 anos de dados (Figura 44d), sendo os piores resultados obtidos a partir da série temporal de 12 meses (Figura 44a). Dentre os atributos SAR considerados, tem-se que a polarização  $\sigma^0$ VV foi a que alcançou os maiores valores de *recall*, para a classe infestado, exceto para a série temporal de 36 meses (Figura 44c).

A Figura 45 apresenta os resultados obtidos a partir da integração de atributos ópticos e SAR em função do tamanho da série temporal. Cabe destacar que nos gráficos são apresentados os resultados obtidos para a classe infestado.

**Figura 45** - Valores obtidos para a métrica *recall* ao combinar atributos ópticos e SAR, em função do tamanho da série temporal.



Fonte: Elaborado pelo autor.

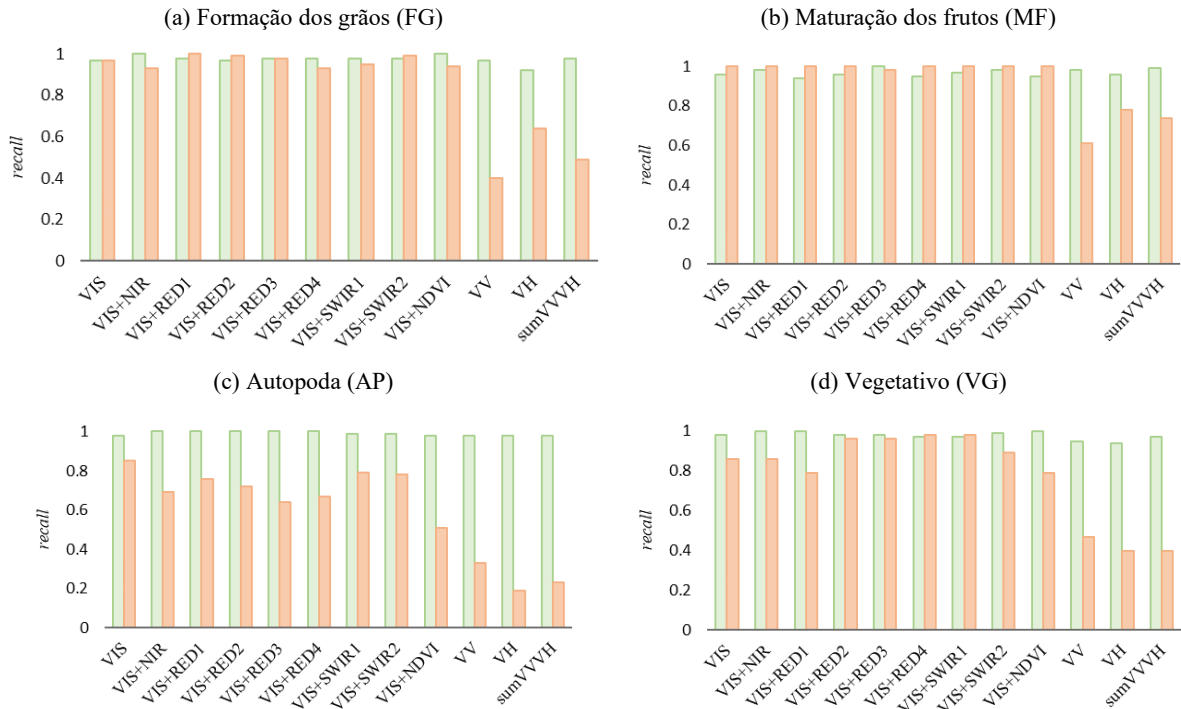
De acordo com a Figura 45a, a combinação de atributos que apresentou melhora em *recall* após a inclusão de atributos SAR foram: VIS+RED4, VIS+SWIR1. A partir da combinação VIS+RED4 obteve-se uma melhora de 0.07 ao inserir a polarização  $\sigma^0$ VV, e para a combinação VIS+SWIR1 alcançou-se uma melhora de 0.06 ao incluir a polarização  $\sigma^0$ VH. Considerando a série temporal de 24 meses (Figura 45b), observou-se uma melhora de 0,06 ao incluir a polarização  $\sigma^0$ VV na combinação VIS+NDVI. Além disso, para essa mesma

combinação de atributos, obteve-se uma melhora de 0,16, para a série temporal de 60 meses (Figura 45e), a partir dos atributos  $\sigma^0$ VH.

#### 4.2.3.2 Cenário 2: Impacto das fases fenológicas na discriminação de áreas infestadas por nematoides

A Figura 46 apresenta os resultados do Cenário 2, considerando os atributos ópticos e SAR separadamente, no qual foi investigado a contribuição de cada fase fenológica na discriminação das áreas infestadas por nematoides. Para isso, foi analisada a métrica *recall* obtida no treinamento dos modelos ajustados a partir de séries temporais constituídas por 15 observações (FG e MF), 10 observações (AP) e 20 observações (VG).

**Figura 46** - Valores obtidos para a métrica *recall* para as diferentes fases fenológicas. As barras nas cores verde e laranja representam as classe sadio e infestado, respectivamente.



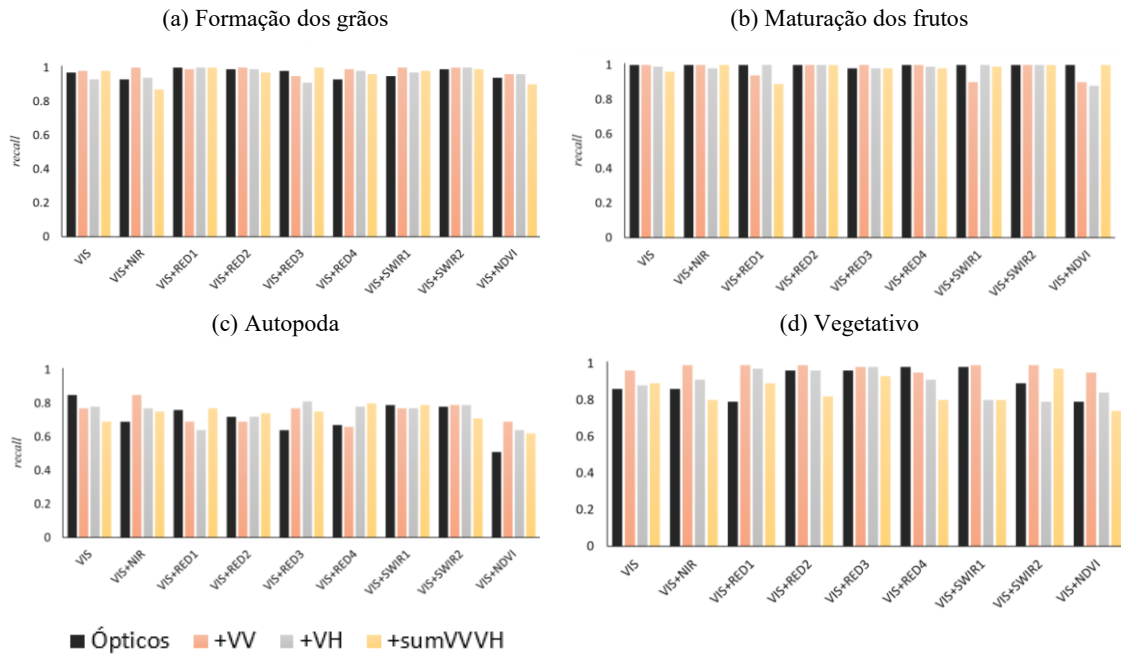
Fonte: Elaborado pelo autor.

De acordo com a Figura 46, nota-se que ao utilizar somente os períodos correspondentes às fases fenológicas é possível obter *recall* acima de 0,7, com exceção da fase AP. De modo geral, foi a fase MF que forneceu os melhores valores de *recall*, tanto para os atributos ópticos quanto para os atributos SAR. Por outro lado, foi a partir da fase AP que foram obtidos os piores resultados para a classe infestado. O pior resultado obtido a partir da fase AP pode estar associado ao fato dessa fase compreender apenas os meses de julho e agosto, e consequentemente, acarretar uma série temporal de menor dimensão.

Em relação às combinações de atributos ópticos para a fase FG, os maiores valores de *recall* foram verificados com VIS+RED1 ( $recall_s = 0,98$  e  $recall_i = 1$ ) e VIS+SWIR2 ( $recall_s = 0,98$  e  $recall_i = 0,99$ ). Em MF, têm-se as combinações VIS+NIR ( $recall_s = 0,98$  e  $recall_i = 1$ ) e VIS+SWIR2 ( $recall_s = 0,98$  e  $recall_i = 1$ ) com os melhores resultados. Além disso, foi verificado que para a fase MF todas as combinações de atributos apresentaram para a classe infestado *recall* igual 1, com exceção da combinação VIS+RED3 ( $recall_i = 0,98$ ). Para a fase AP, os valores de *recall* foram consideravelmente inferiores àqueles observados nas demais fases fenológicas, ainda assim foram obtidos resultados satisfatórios ao considerar a combinação de atributos VIS ( $recall_s = 0,98$  e  $recall_i = 0,85$ ). Por fim, na fase VG, as combinações VIS+RED4 e VIS+SWIR1 apresentaram resultados semelhantes com  $recall_s = 0,97$  e  $recall_i = 0,98$ . Quanto aos atributos SAR, a polarização  $\sigma^0$ VH foi a que demonstrou melhor desempenho para as fases FG ( $recall_s = 0,92$  e  $recall_i = 0,64$ ) e MF ( $recall_s = 0,96$  e  $recall_i = 0,78$ ), já para as fases AP ( $recall_s = 0,98$  e  $recall_i = 0,33$ ) e VG ( $recall_s = 0,95$  e  $recall_i = 0,47$ ) foi a polarização  $\sigma^0$ VV que apresentou os melhores resultados.

A Figura 47 apresenta os resultados do Cenário 2, no qual foi investigado a contribuição dos atributos SAR, para cada uma das combinações de atributos e fases fenológicas. Destaca-se que os valores da métrica indicada na Figura 47 refere-se aos resultados da classe infestado.

**Figura 47** - Valores obtidos para a métrica *recall* para as diferentes fases fenológicas.



Fonte: Elaborado pelo autor.

Em relação a integração de dados SAR (Figura 47), de modo geral, as maiores contribuições foram observadas para as fases AP e VG, sendo estas aquelas que apresentaram

menores valores de *recall* ao se utilizar apenas dados ópticos (Figura 46). Para a fase AP, por exemplo, a partir da combinação VIS+NIR foi alcançada uma melhora de 0,16 ao incluir a polarização  $\sigma^0VV$  e para a combinação VIS+RED3 obteve-se melhora de, aproximadamente, 0,17. Para a fase VG, considerando a combinação de atributos VIS e VIS+RED1 obteve-se uma melhora 0,10 e 0,20 com a inserção da polarização  $\sigma^0VV$ , respectivamente.

#### 4.2.3.3 Aplicação da rede BiLSTM na área teste considerando o Cenário 1

Devido à dificuldade em se obter dados de verdade terrestre para análise das classificações das séries temporais de diferentes tamanhos (12, 24, 36, 48 e 60 meses), optou-se por tomar os resultados da métrica F-Score como inferência para os resultados obtidos a partir da aplicação da rede BiLSTM (Seção 4.2.2.1) para classificação da área teste (Figura 43). A aquisição de dados de referência para certificação da ocorrência de nematoides é dificultada pelo alto custo de testes nematológicos, além da dificuldade de acesso às áreas produtoras para realização desse tipo de teste. Assim sendo, a Tabela 16 apresenta os valores de F-Score obtidos a partir do treinamento da rede BiLSTM, considerando o Cenário 1 e as combinações de atributos ópticos. Os resultados são apresentados considerando as combinações de atributos por tamanho da série temporal (12, 24, 36, 48 e 60 meses).

**Tabela 16** - F-Score para a combinação de atributos ópticos. S representa a classe sadio e I representa a classe infestado. O gradiente de cores indica os valores da métrica F-Score em ordem decrescente

| Atributos | 12 meses |      | 24 meses |      | 36 meses |      | 48 meses |      | 60 meses |      |
|-----------|----------|------|----------|------|----------|------|----------|------|----------|------|
|           | S        | I    | S        | I    | S        | I    | S        | I    | S        | I    |
| VIS       | 0.97     | 0.92 | 0.98     | 0.94 | 0.99     | 0.98 | 1        | 0.99 | 0.99     | 0.97 |
| VIS+NIR   | 0.98     | 0.95 | 0.98     | 0.95 | 0.99     | 0.97 | 0.99     | 0.97 | 1        | 0.99 |
| VIS+RED1  | 0.98     | 0.93 | 0.98     | 0.95 | 0.98     | 0.95 | 0.99     | 0.98 | 0.99     | 0.98 |
| VIS+RED2  | 0.98     | 0.95 | 0.98     | 0.94 | 0.99     | 0.97 | 1        | 0.99 | 0.99     | 0.98 |
| VIS+RED3  | 0.99     | 0.95 | 0.98     | 0.95 | 1        | 0.99 | 1        | 0.99 | 0.99     | 0.97 |
| VIS+RED4  | 0.98     | 0.93 | 1        | 0.99 | 0.99     | 0.97 | 0.99     | 0.97 | 0.99     | 0.98 |
| VIS+SWIR1 | 0.97     | 0.89 | 0.99     | 0.96 | 0.99     | 0.98 | 1        | 0.99 | 0.99     | 0.98 |
| VIS+SWIR2 | 0.98     | 0.93 | 0.98     | 0.94 | 1        | 0.99 | 1        | 0.99 | 0.99     | 0.98 |
| VIS+NDVI  | 0.96     | 0.87 | 0.97     | 0.92 | 0.99     | 0.97 | 0.99     | 0.97 | 0.97     | 0.91 |

Fonte: Elaborado pelo autor.

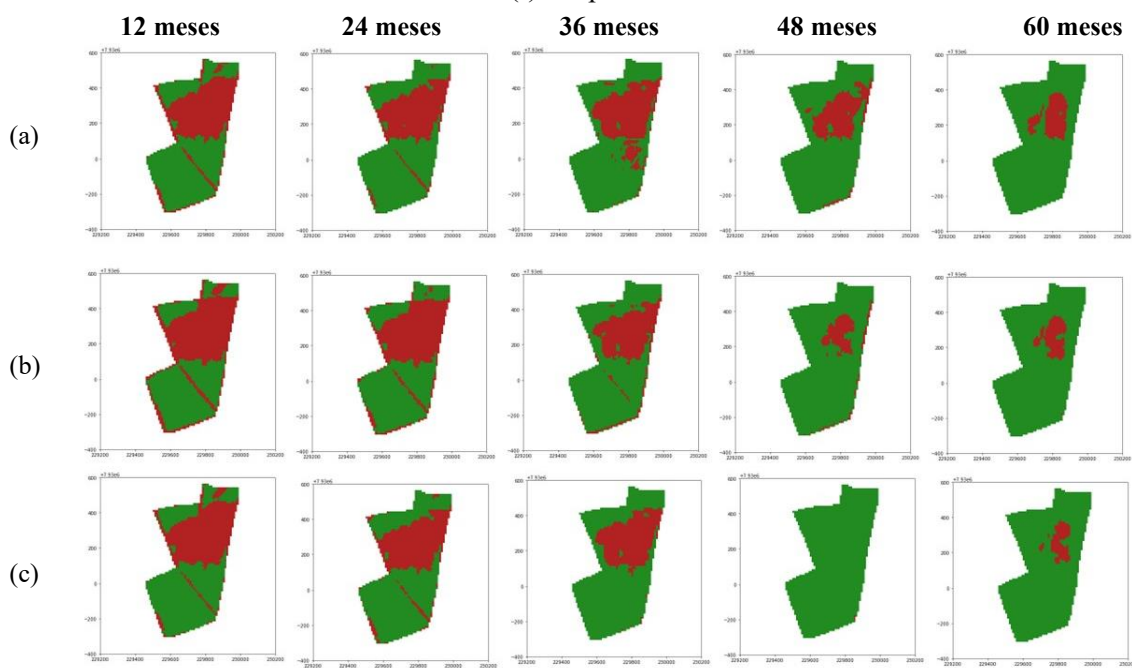
De acordo com a Tabela 16, é observado que os valores de F-Score tendem a aumentar com o aumento da série temporal, sendo os piores resultados obtidos a partir da série temporal de 12 meses. Ainda assim, os menores valores de F-Score foram de 0,96 para a classe sadio e 0,87 para a classe infestado, ambos para a combinação VIS+NDVI. Considerando a série temporal de 24 meses, a combinação de atributos que forneceu melhores resultados foi

VIS+RED4, seguida por VIS+SWIR1. A partir da série temporal de 36 meses, foram as combinações VIS+SWIR2, VIS+RED3 que forneceram os melhores resultados. Para 48 meses, os maiores valores foram adquiridos a partir das combinações VIS, VIS+RED2, VIS+RED3, VIS+SWIR1 e VIS+SWIR2, ambas com F-Score de 0,99 para a classe infestado e 1 para a classe sadio. Por fim, para a série temporal de 60 meses, foi a combinação VIS+NIR que alcançou os melhores resultados, tanto para a classe sadio quanto para a classe infestado.

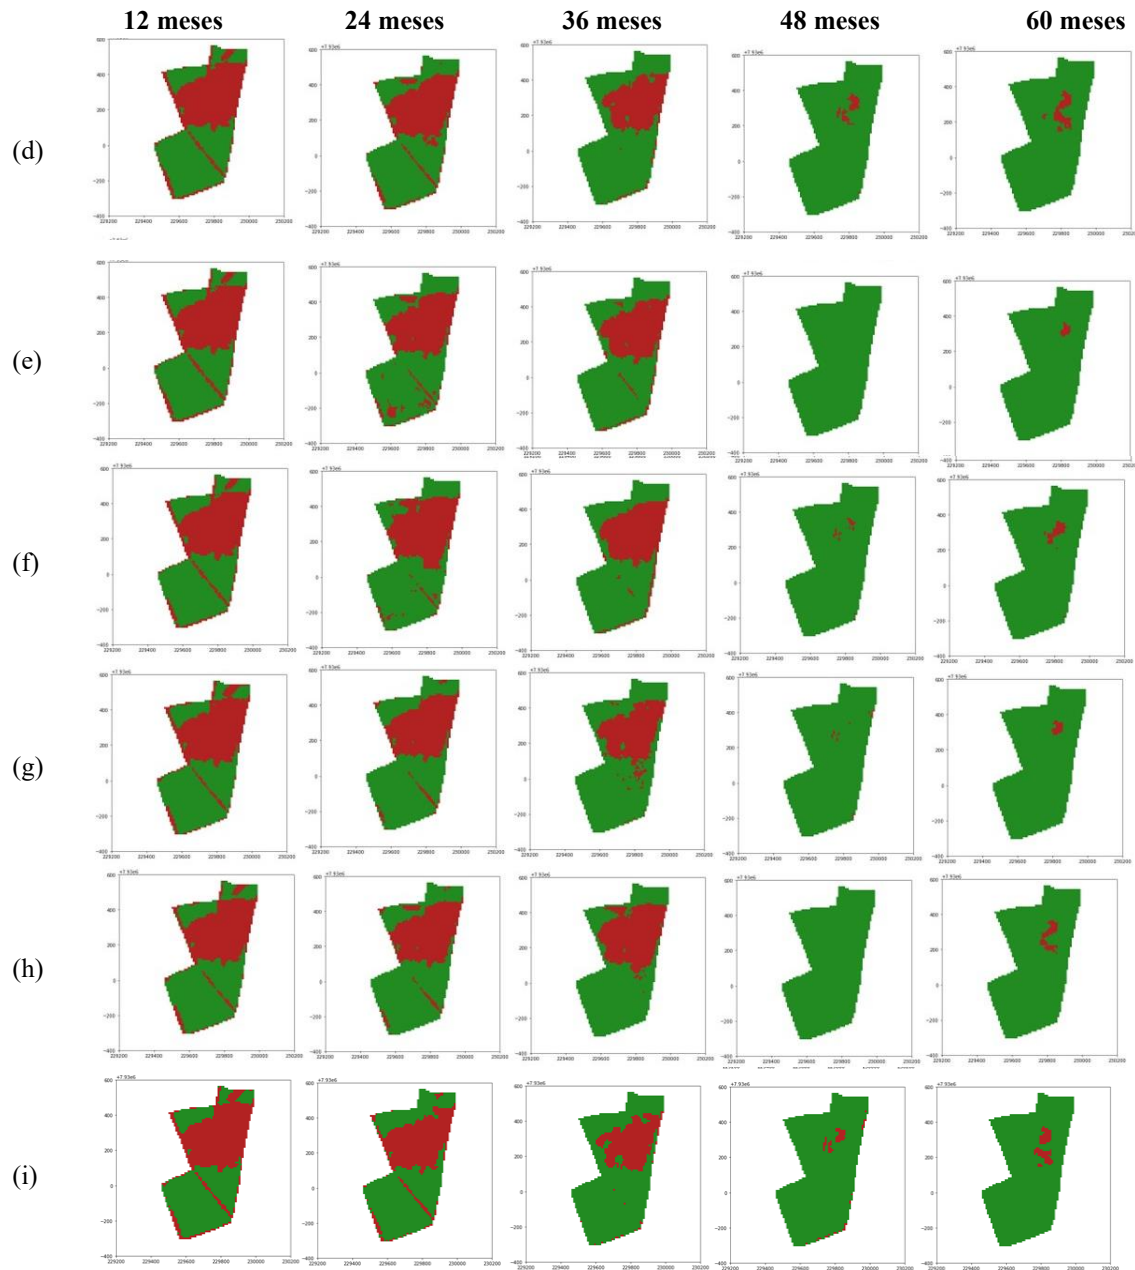
Os maiores valores de F-Score, de modo geral, foram obtidos a partir da série temporal de 48 meses. Diante disso, ao comparar esses valores com os resultados da série temporal de 12 meses, para a classe infestado, obteve-se uma melhora de 0,1 a partir das combinação VIS+NDVI e VIS+SWIR1.

A Figura 48 apresenta os mapas de infestação considerando cada uma das combinações de atributos apresentadas na Tabela 16. É observado que as classificações apresentam resultados semelhantes até 36 meses, a partir desse período é verificado resultado divergente dos anos anteriores. As classificações considerando 48 e 60 meses, apresentaram a área detectada como infestada consideravelmente menor que as demais classificações. Ainda assim, a localização das áreas detectadas como infestadas é condizente com as demais classificações. Esses resultados corroboram com os perfis temporais apresentados na Figura 31 (Seção 4.1.3.1), nos quais é perceptível uma mudança no comportamento da série temporal a partir de 2020.

**Figura 48** – Distribuição espacial de áreas infestadas por nematoides a partir de dados ópticos: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



**Figura 48** – Distribuição espacial de áreas infestadas por nematoides a partir de dados ópticos: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



Fonte: Elaborado pelo autor.

Ainda de acordo com Figura 48, é verificado que todas as combinações de atributos forneceram resultados similares em relação a dimensão e localização da área infestada, com exceção das séries temporais de 48 e 60 meses. No entanto, é observado, nas classificações das séries temporais de 12 e 24 meses, a detecção de carreadores como área infestada. Além disso, é verificado que em todas as classificações o padrão de distribuição da área infestada obedece a um padrão de ocorrência dos nematoides, sendo normalmente distribuídos em reboleiras.

A Tabela 17 sintetiza os resultados obtidos a partir da aplicação da rede BiLSTM aos atributos SAR ( $\sigma^0VV$ ,  $\sigma^0VH$  e  $\text{sumVVVH}$ ). Conforme pode ser verificado, o tamanho da série temporal tem forte influência nos valores de F-Score. Considerando a série temporal de 12 meses, o melhor resultado foi a partir do atributo  $\text{sumVVVH}$  ( $F\text{-Score}_s = 0,89$  e  $F\text{-Score}_i = 0,48$ ), seguido por  $\sigma^0VV$  ( $F\text{-Score}_s = 0,89$  e  $F\text{-Score}_i = 0,44$ ) e  $\sigma^0VH$  ( $F\text{-Score}_s = 0,89$  e  $F\text{-Score}_i = 0,41$ ). Com o incremento do tamanho da série temporal, obteve-se melhora de 0,44 e de 0,39 a partir das polarizações  $\sigma^0VH$  e  $\sigma^0VV$ , respectivamente. Esses resultados corroboram com Zhao *et al.* (2019), quando verificaram que à medida que o tamanho da série temporal aumentou, as precisões das redes LSTM e *Gated Recurrent Unit* (GRU) aumentaram significativamente, o que pode estar associado às dependências de longo prazo.

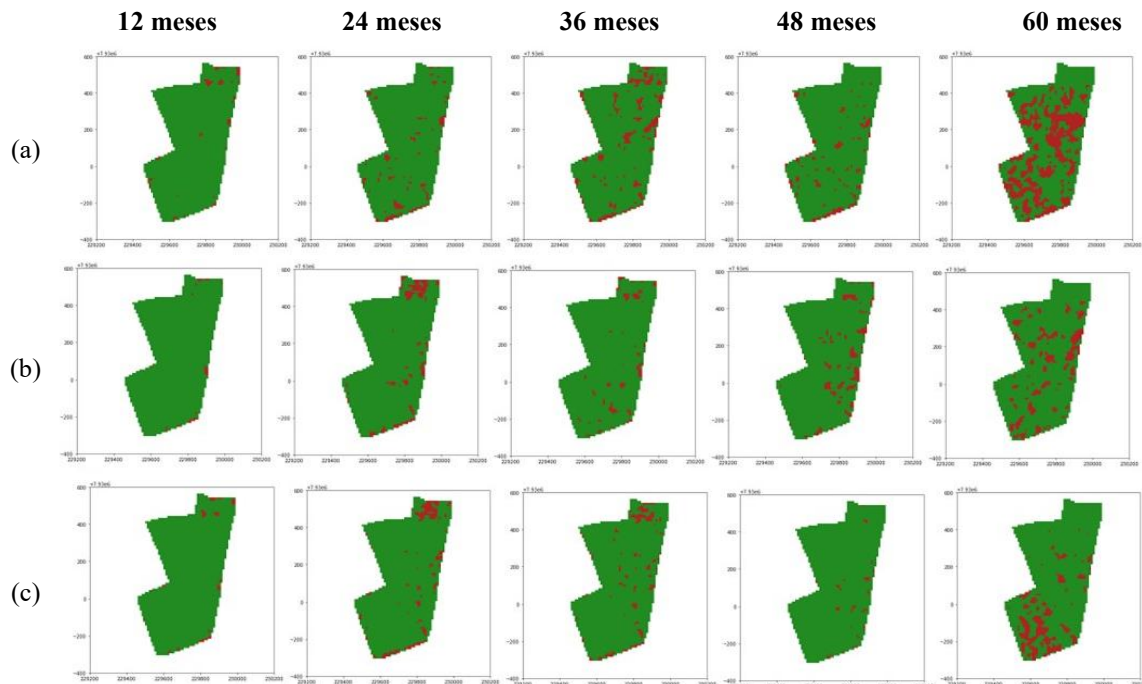
**Tabela 17** - F-Score para os atributos SAR. S representa a classe sadio e I representa a classe infestado. O gradiente de cores indica os valores da métrica F-Score em ordem decrescente.

| ST               | 12 meses |      | 24 meses |      | 36 meses |      | 48 meses |      | 60 meses |      |
|------------------|----------|------|----------|------|----------|------|----------|------|----------|------|
|                  | S        | I    | S        | I    | S        | I    | S        | I    | S        | I    |
| $\sigma^0VV$     | 0.89     | 0.44 | 0.91     | 0.64 | 0.92     | 0.65 | 0.93     | 0.8  | 0.94     | 0.83 |
| $\sigma^0VH$     | 0.89     | 0.41 | 0.92     | 0.63 | 0.93     | 0.73 | 0.94     | 0.83 | 0.96     | 0.85 |
| $\text{sumVVVH}$ | 0.89     | 0.48 | 0.92     | 0.64 | 0.93     | 0.74 | 0.94     | 0.75 | 0.95     | 0.83 |

Fonte: Elaborado pelo autor.

A Figura 49 apresenta a distribuição de áreas infestadas por nematoides, detectadas a partir das séries temporais de atributos SAR ( $\sigma^0VV$ ,  $\sigma^0VH$  e  $\text{sumVVVH}$ ), em que se verifica um aumento nas áreas detectadas como infestadas com o aumento da série temporal para todos os atributos. Além disso, é observado que as áreas identificadas como infestadas diferem daquelas identificadas a partir dos atributos ópticos, principalmente na dimensão das áreas detectadas. Apesar de estarem localizadas na mesma região daquelas detectadas a partir das combinações de atributos ópticos, as áreas detectadas a partir dos atributos SAR são menores e mais fragmentadas. Outro ponto, é que foram detectadas áreas infestadas na porção sul da área teste, a partir das séries temporais de 36, 48 e 60 meses, o que não foi identificado a partir das classificações com atributos ópticos.

**Figura 49** - Detecção de área infestada por nematoides a partir de atributos SAR: (a)  $\sigma^0VV$ , (b)  $\sigma^0VH$  e (c)  $\text{sumVVVH}$ . A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



Fonte: Elaborado pelo autor.

As Tabela 18, 19 e 20 apresentam os resultados alcançados considerando a combinação de atributos ópticos e SAR. Em verde, é destacado melhora ao integrar dados SAR, em vermelho é destacado a piora ao adicionar dados SAR, e em azul é destacado a não alteração nos valores de F-Score.

**Tabela 18** - F-Score para a combinação de ópticos e a polarização  $\sigma^0VV$ .

| Série temporal | 12 meses |      | 24 meses |      | 36 meses |      | 48 meses |      | 60 meses |      |
|----------------|----------|------|----------|------|----------|------|----------|------|----------|------|
|                | S        | I    | S        | I    | S        | I    | S        | I    | S        | I    |
| VIS            | 0.97     | 0.88 | 0.98     | 0.94 | 1.00     | 0.99 | 1.00     | 0.99 | 1.00     | 0.99 |
| VIS+NIR        | 0.97     | 0.88 | 0.97     | 0.9  | 1.00     | 0.99 | 0.99     | 0.96 | 0.98     | 0.93 |
| VIS+RED1       | 0.98     | 0.93 | 0.97     | 0.9  | 1.00     | 0.99 | 1.00     | 0.99 | 0.99     | 0.95 |
| VIS+RED2       | 0.97     | 0.88 | 0.98     | 0.93 | 1.00     | 0.99 | 0.99     | 0.98 | 0.98     | 0.95 |
| VIS+RED3       | 0.96     | 0.87 | 0.98     | 0.94 | 0.99     | 0.98 | 1.00     | 0.99 | 0.99     | 0.97 |
| VIS+RED4       | 0.95     | 0.88 | 0.98     | 0.94 | 0.99     | 0.98 | 1.00     | 0.99 | 0.98     | 0.95 |
| VIS+SWIR1      | 0.97     | 0.89 | 0.98     | 0.96 | 1.00     | 0.99 | 0.99     | 0.98 | 0.99     | 0.98 |
| VIS+SWIR2      | 0.97     | 0.89 | 0.99     | 0.88 | 1.00     | 0.99 | 0.99     | 0.97 | 0.99     | 0.98 |
| VIS+NDVI       | 0.96     | 0.87 | 0.98     | 0.95 | 0.98     | 0.94 | 1.00     | 0.99 | 0.99     | 0.97 |

Fonte: Elaborado pelo autor.

**Tabela 19** - F-Score para a combinação de ópticos e a polarização  $\sigma^0VH$ .

| Série temporal | 12 meses |      | 24 meses |      | 36 meses |      | 48 meses |      | 60 meses |      |
|----------------|----------|------|----------|------|----------|------|----------|------|----------|------|
|                | S        | I    | S        | I    | S        | I    | S        | I    | S        | I    |
| VIS            | 0.97     | 0.89 | 0.97     | 0.92 | 1.00     | 0.99 | 0.99     | 0.97 | 1.00     | 0.99 |
| VIS+NIR        | 0.98     | 0.92 | 0.98     | 0.95 | 1.00     | 0.99 | 1.00     | 0.99 | 0.99     | 0.97 |
| VIS+RED1       | 0.97     | 0.92 | 0.99     | 0.97 | 1.00     | 0.99 | 1.00     | 0.99 | 1.00     | 0.99 |
| VIS+RED2       | 0.97     | 0.88 | 0.98     | 0.94 | 0.99     | 0.96 | 1.00     | 0.99 | 1.00     | 0.99 |
| VIS+RED3       | 0.97     | 0.88 | 0.94     | 0.86 | 1.00     | 0.99 | 1.00     | 0.99 | 1.00     | 0.99 |
| VIS+RED4       | 0.97     | 0.88 | 0.99     | 0.96 | 1.00     | 0.99 | 0.99     | 0.98 | 0.98     | 0.93 |

**Tabela 19** - F-Score para a combinação de ópticos e a polarização  $\sigma^0$ VH.

| Série temporal | 12 meses |      | 24 meses |      | 36 meses |      | 48 meses |      | 60 meses |      |
|----------------|----------|------|----------|------|----------|------|----------|------|----------|------|
|                | S        | I    | S        | I    | S        | I    | S        | I    | S        | I    |
| VIS+SWIR1      | 0.98     | 0.92 | 0.98     | 0.95 | 1.00     | 0.99 | 1.00     | 0.99 | 0.98     | 0.95 |
| VIS+SWIR2      | 0.98     | 0.95 | 0.98     | 0.93 | 1.00     | 1    | 1.00     | 0.99 | 0.99     | 0.98 |
| VIS+NDVI       | 0.97     | 0.89 | 0.98     | 0.95 | 0.99     | 0.97 | 0.99     | 0.98 | 1.00     | 0.99 |

Fonte: Elaborado pelo autor.

**Tabela 20** - F-Score para a combinação de ópticos e o atributo sumVVVH.

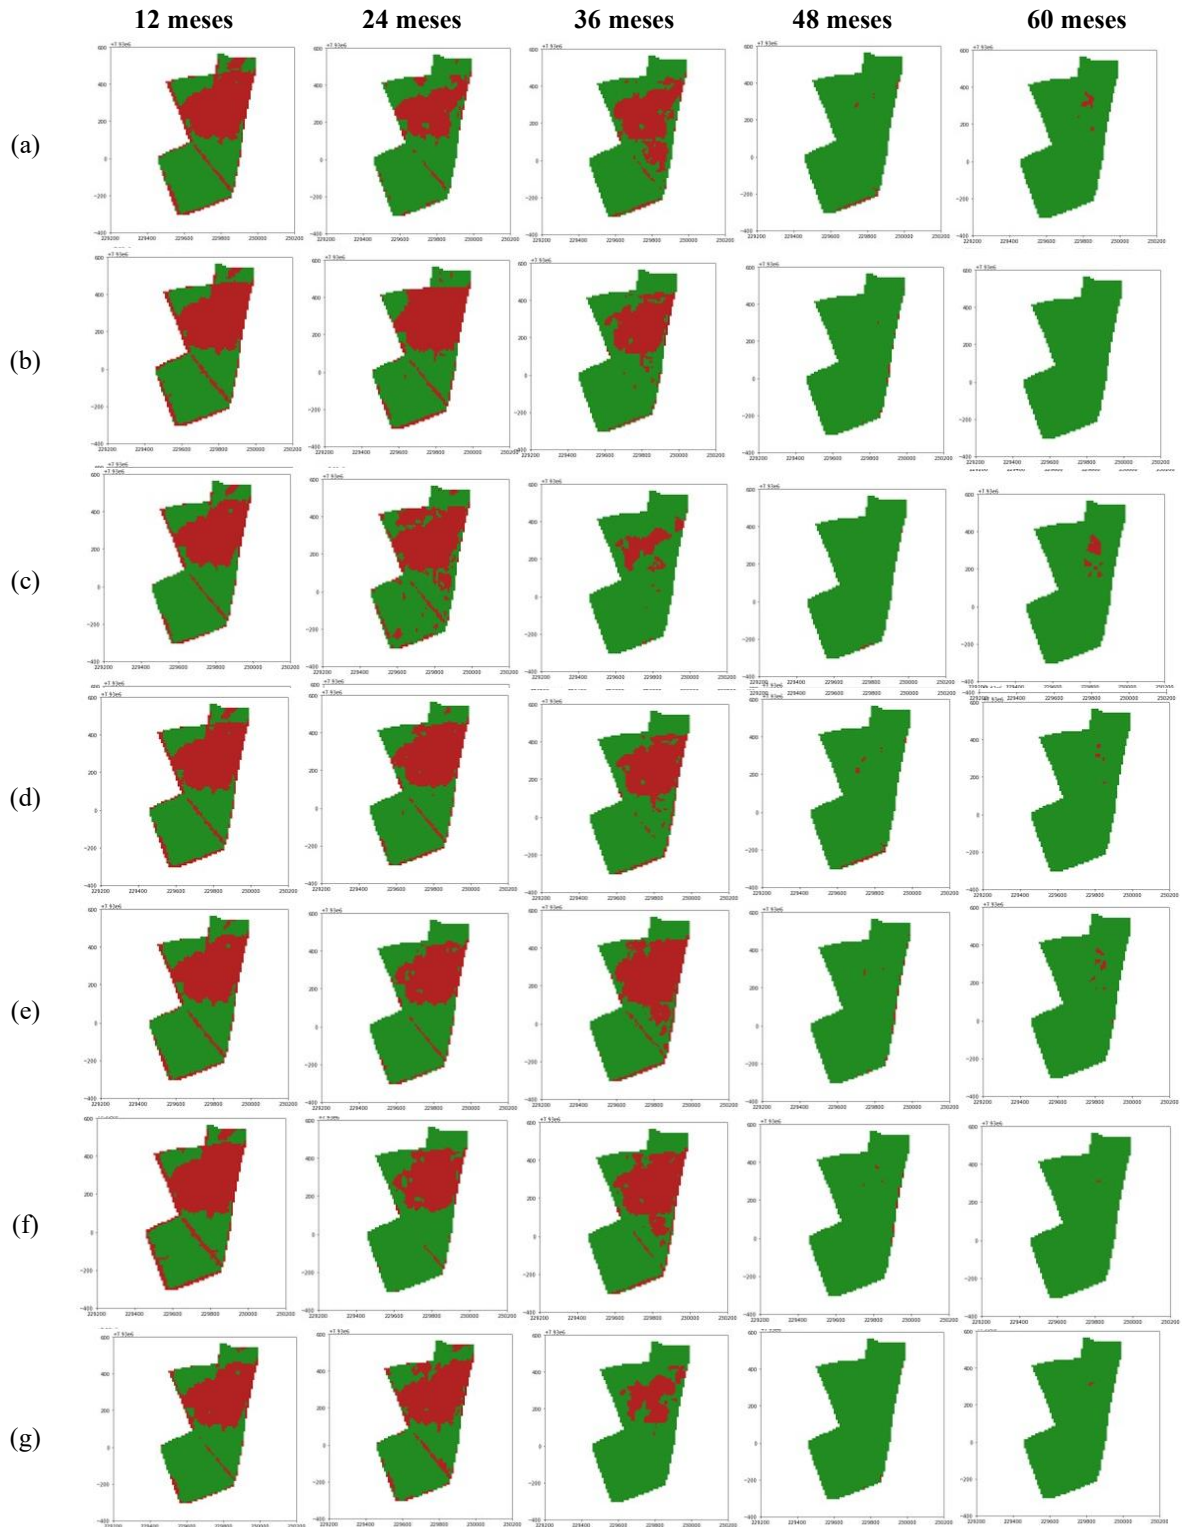
| Série temporal | 12 meses |      | 24 meses |      | 36 meses |      | 48 meses |      | 60 meses |      |
|----------------|----------|------|----------|------|----------|------|----------|------|----------|------|
|                | S        | I    | S        | I    | S        | I    | S        | I    | S        | I    |
| VIS            | 0.97     | 0.88 | 0.98     | 0.93 | 0.99     | 0.97 | 1.00     | 0.99 | 0.98     | 0.94 |
| VIS+NIR        | 0.97     | 0.92 | 0.98     | 0.93 | 1.00     | 0.99 | 1.00     | 0.99 | 0.99     | 0.98 |
| VIS+RED1       | 0.97     | 0.91 | 0.98     | 0.94 | 1.00     | 0.99 | 1.00     | 0.99 | 0.99     | 0.97 |
| VIS+RED2       | 0.97     | 0.89 | 0.98     | 0.93 | 1.00     | 0.99 | 1.00     | 0.99 | 0.99     | 0.96 |
| VIS+RED3       | 0.97     | 0.88 | 0.97     | 0.92 | 0.99     | 0.98 | 0.99     | 0.98 | 1.00     | 0.99 |
| VIS+RED4       | 0.98     | 0.94 | 0.98     | 0.95 | 1.00     | 0.99 | 1.00     | 0.99 | 1.00     | 0.99 |
| VIS+SWIR1      | 0.97     | 0.89 | 0.99     | 0.97 | 0.99     | 0.97 | 1.00     | 0.99 | 1.00     | 0.99 |
| VIS+SWIR2      | 0.96     | 0.88 | 0.99     | 0.97 | 1.00     | 0.99 | 1.00     | 0.99 | 1.00     | 0.99 |
| VIS+NDVI       | 0.97     | 0.88 | 0.98     | 0.93 | 1.00     | 0.99 | 0.99     | 0.98 | 0.97     | 0.90 |

Fonte: Elaborado pelo autor.

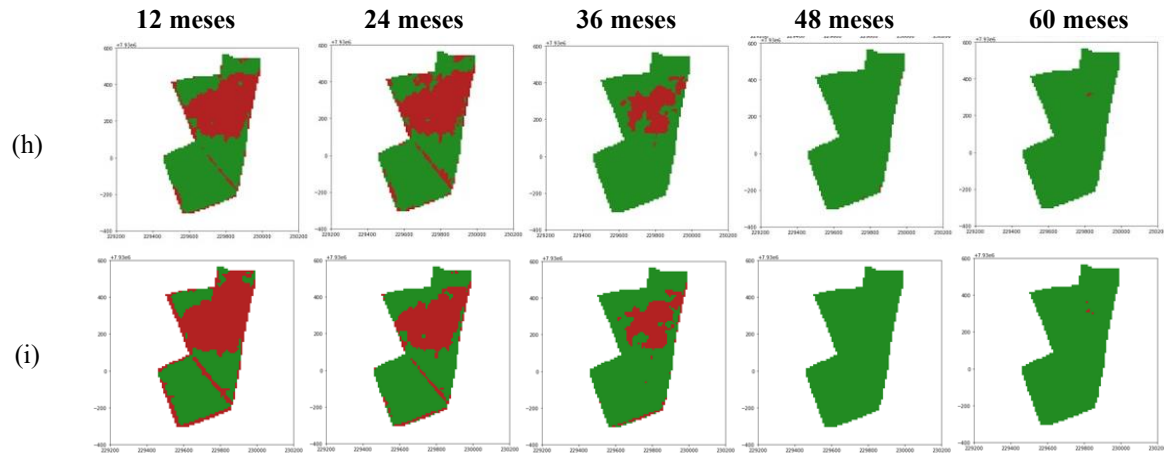
Ao comparar os resultados da integração de dados SAR com os apresentados na Tabela 16, tem-se que a contribuição são principalmente para as séries temporais de 36 meses. Para as séries temporais de menor tamanho (12 e 24 meses) em muitos casos os atributos SAR pioram os resultados obtidos ao se utilizar somente atributos ópticos. Ao inserir a polarização  $\sigma^0$ VH na combinação de atributos VIS+NDVI (Tabela 19), obteve-se melhora dos resultados da classe infestado em todas as dimensões da série temporal (exceto para 36 meses), sendo a maior contribuição de 0,08 a partir da série temporal de 60 meses. A inserção da polarização  $\sigma^0$ VH na combinação VIS+RED1 também demonstrou melhora para a classe infestado em todas as séries temporais, exceto para a de 12 meses.

Na Figura 50, são apresentados os mapas da classificação considerando a combinação de atributos ópticos e a polarização  $\sigma^0$ VV. As demais classificações, resultantes das combinações de atributos ópticos e SAR, por terem apresentado resultados similares aos obtidos a partir da polarização  $\sigma^0$ VV, são apresentadas na Figura 1 do Apêndice D. Percebe-se que a distribuição espacial de áreas infestadas é similar àquela utilizando somente dados ópticos. No entanto, é observado que a adição de SAR tende a reduzir o tamanho da área detectada como área infestada. Esse efeito é perceptível, principalmente, a partir das classificações considerando as séries temporais de 60 meses, nas quais a área detectada como infestada foi consideravelmente reduzida.

**Figura 50** - Detecção de área infestada por nematoides a partir da combinação de dados ópticos e a polarização  $\sigma^0$ VV: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



**Figura 50** - Detecção de área infestada por nematoides a partir da combinação de dados ópticos e a polarização  $\sigma^0$ VV: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



Fonte: Elaborado pelo autor.

#### 4.2.3.4 Aplicação da rede BiLSTM na área teste considerando o Cenário 2

A Tabela 21 apresenta os valores de F-Score obtidos a partir da rede BiLSTM, considerando o Cenário 2 e as combinações de atributos ópticos. Os resultados são apresentados considerando a combinação de atributos de séries temporais construídas por fase fenológica (FG: formação dos grãos – 15 observações, MF: maturação dos frutos – 15 observações, AP: autopoda – 10 observações e VG: fase vegetativa – 20 observações).

**Tabela 21** - F-Score para a combinação de atributos ópticos. S representa a classe sadio e I representa a classe infestado. O gradiente de cores indica os valores da métrica F-Score em ordem decrescente.

| Fases<br>Atributos | FG   |      | MF   |      | AP   |      | VG   |      |
|--------------------|------|------|------|------|------|------|------|------|
|                    | S    | I    | S    | I    | S    | I    | S    | I    |
| VIS                | 0.98 | 0.95 | 0.98 | 0.95 | 0.96 | 0.89 | 0.97 | 0.90 |
| VIS+NIR            | 0.99 | 0.96 | 0.99 | 0.97 | 0.95 | 0.82 | 0.98 | 0.93 |
| VIS+RED1           | 0.99 | 0.97 | 0.97 | 0.92 | 0.96 | 0.86 | 0.97 | 0.88 |
| VIS+RED2           | 0.98 | 0.95 | 0.98 | 0.94 | 0.96 | 0.84 | 0.99 | 0.96 |
| VIS+RED3           | 0.99 | 0.96 | 0.99 | 0.98 | 0.94 | 0.78 | 0.98 | 0.95 |
| VIS+RED4           | 0.98 | 0.93 | 0.97 | 0.92 | 0.95 | 0.81 | 0.98 | 0.94 |
| VIS+SWIR1          | 0.98 | 0.95 | 0.98 | 0.95 | 0.96 | 0.87 | 0.98 | 0.95 |
| VIS+SWIR2          | 0.99 | 0.96 | 0.99 | 0.96 | 0.96 | 0.87 | 0.98 | 0.93 |
| VIS+NDVI           | 0.99 | 0.96 | 0.98 | 0.94 | 0.91 | 0.65 | 0.97 | 0.88 |

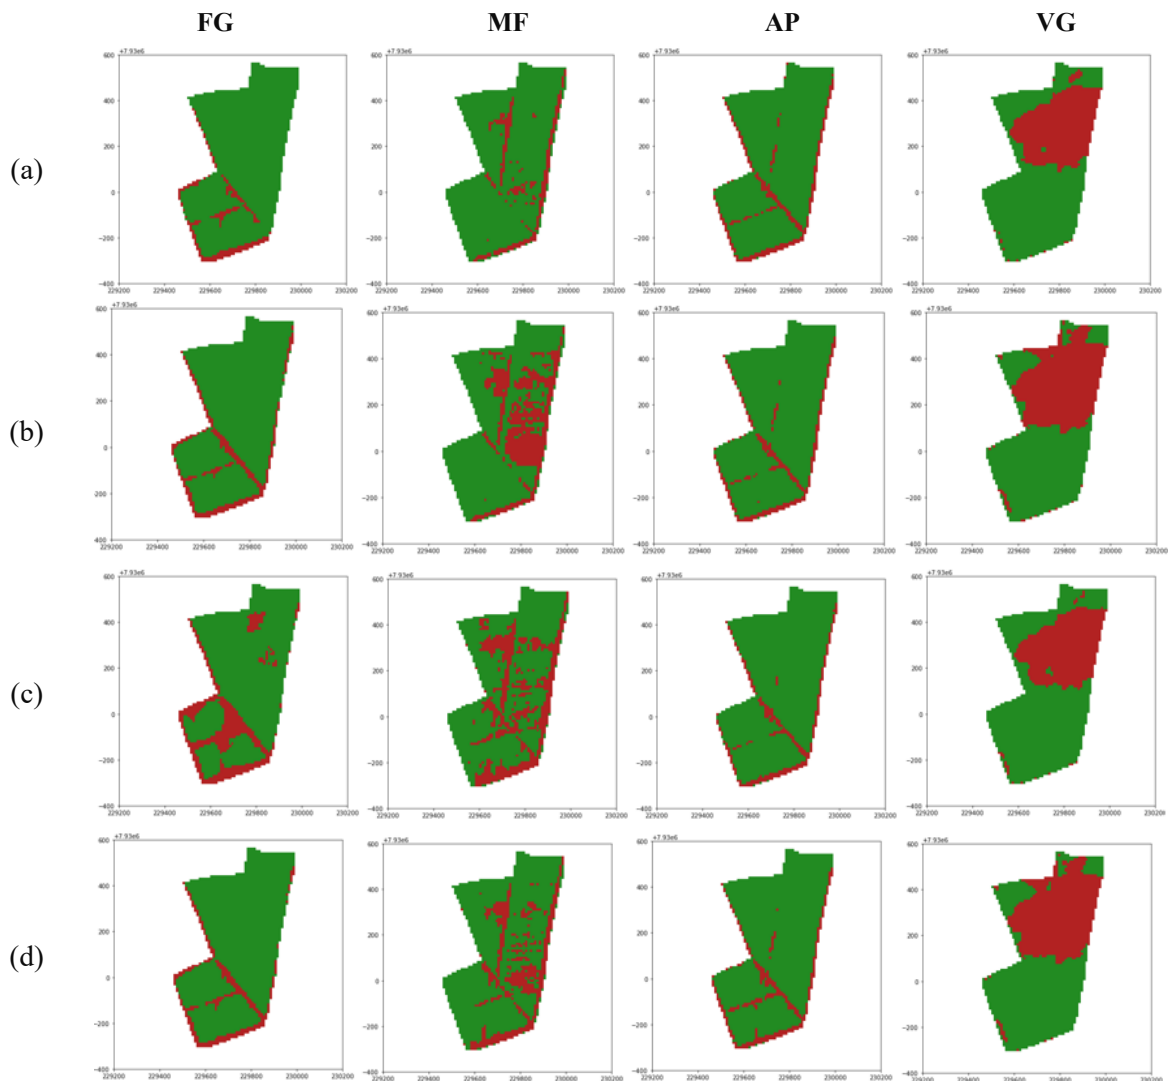
Fonte: Elaborado pelo autor.

De acordo com a Tabela 21, as fases fenológicas que apresentaram os menores valores de F-Score foram as fases AP e VG. Por outro lado, os melhores resultados foram com as fases FG e MF. Considerando a fase FG, a combinação de atributos que apresentou os maiores valores de F-Score foi VIS+RED1 (F-Score<sub>s</sub> = 0,99 e F-Score<sub>i</sub> = 0,97). Para a fase MF, o melhor resultado foi a partir da combinação VIS+RED3 (F-Score<sub>s</sub> = 0,99 e F-Score<sub>i</sub> = 0,98), já para


a fase AP, atingiu-se resultados similares para as combinações VIS+SWIR1 ( $F\text{-Score}_s = 0,96$  e  $F\text{-Score}_i = 0,87$ ) e VIS+SWIR2 ( $F\text{-Score}_s = 0,96$  e  $F\text{-Score}_i = 0,87$ ), porém os melhores resultados foram obtidos a partir da classe VIS ( $F\text{-Score}_s = 0,96$  e  $F\text{-Score}_i = 0,89$ ). Ainda considerando a fase AP, foi verificado que a combinação VIS+NDVI ( $F\text{-Score}_s = 0,91$  e  $F\text{-Score}_i = 0,65$ ) apresentou resultado discrepante em relação às outras combinações de atributos. Por fim, para a fase VG também foram alcançados resultados similares para as combinações VIS+RED3 e VIS+SWIR1 com  $F\text{-Score}_s = 0,98$  e  $F\text{-Score}_i = 0,95$ .

A Figura 51 apresenta as classificações considerando cada uma das combinações de atributos apresentadas na Tabela 21.

**Figura 51** – Distribuição espacial de áreas infestadas por nematoides a partir de dados ópticos: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



**Figura 51** – Distribuição espacial de áreas infestadas por nematoides a partir de dados ópticos: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



Fonte: Elaborado pelo autor.

Os resultados da classificação considerando apenas atributos ópticos mostram que as áreas detectadas como infestadas diferem daquelas detectadas no Cenário 1 (Figura 48). Nota-se ainda que os resultados diferem de uma fase fenológica para outra. Para a fase FG, nota-se que, para todas as combinações de atributos, as áreas detectadas como infestadas referem-se a carregadores que delimitam talhões. Esse resultado também é similar ao obtido para a fase AP.

A partir das fases MF e VG, obteve-se a maior proporção de áreas detectadas como infestadas, porém com resultados divergentes entre si. Para a fase MF, observa-se uma grande área detectada como infestada, na porção leste da área classificada, utilizando as combinações VIS+NIR (Figura 51b), VIS+RED1 (Figura 51c), VIS+RED2 (Figura 51d), VIS+RED3 (Figura 51e) e VIS+RED4 (Figura 51g). Além disso, é possível perceber que para as combinações VIS+NIR (Figura 51b), VIS+RED1 (Figura 51c), VIS+RED2 (Figura 51d) o classificador apresentou a área classificada como infestada condizente com o direcionamento das linhas de plantio. Quando se observa as classificações da fase VG, todas as combinações de atributos apresentaram resultados semelhantes entre si. Esses resultados diferentes das demais fases fenológicas, contudo é similar aos obtidos a partir dos resultados do Cenário 1 que consideraram as séries temporais de 12, 24 e 36 meses. Diante desse contexto, é plausível supor que os resultados do Cenário 1 possam ter sido impactados pelas informações associadas aos meses correspondentes a fase VG.

A Tabela 22 apresenta os resultados obtidos a partir dos atributos SAR, considerando cada fase fenológica. Ao utilizar somente atributos SAR, os resultados são consideravelmente inferiores aos obtidos a partir dos dados ópticos. Dentre as fases fenológicas, a fase AP foi a que forneceu os menores valores de F-Score ( $\sigma^0VV = 0,47$ ;  $\sigma^0VH = 0,30$  e  $\text{sumVVVH} = 0,45$ ) para a classe infestado. Esse resultado pode estar relacionado com o tamanho da série temporal, ou seja, ao considerar somente a fase AP, a qual ocorre entre os meses de julho e agosto, é obtido uma série temporal de menor dimensão (10 intervalos de tempo). Por sua vez, a fase MF foi a que apresentou os melhores resultados, especialmente a partir do atributo  $\text{sumVVH}$  (F-Score<sub>s</sub> = 0,96 e F-Score<sub>i</sub> = 0,84). Por fim, ao considerar a fase FG, polarização  $\sigma^0VH$  foi a que apresentou os maiores valores de F-Score para a classe infestado

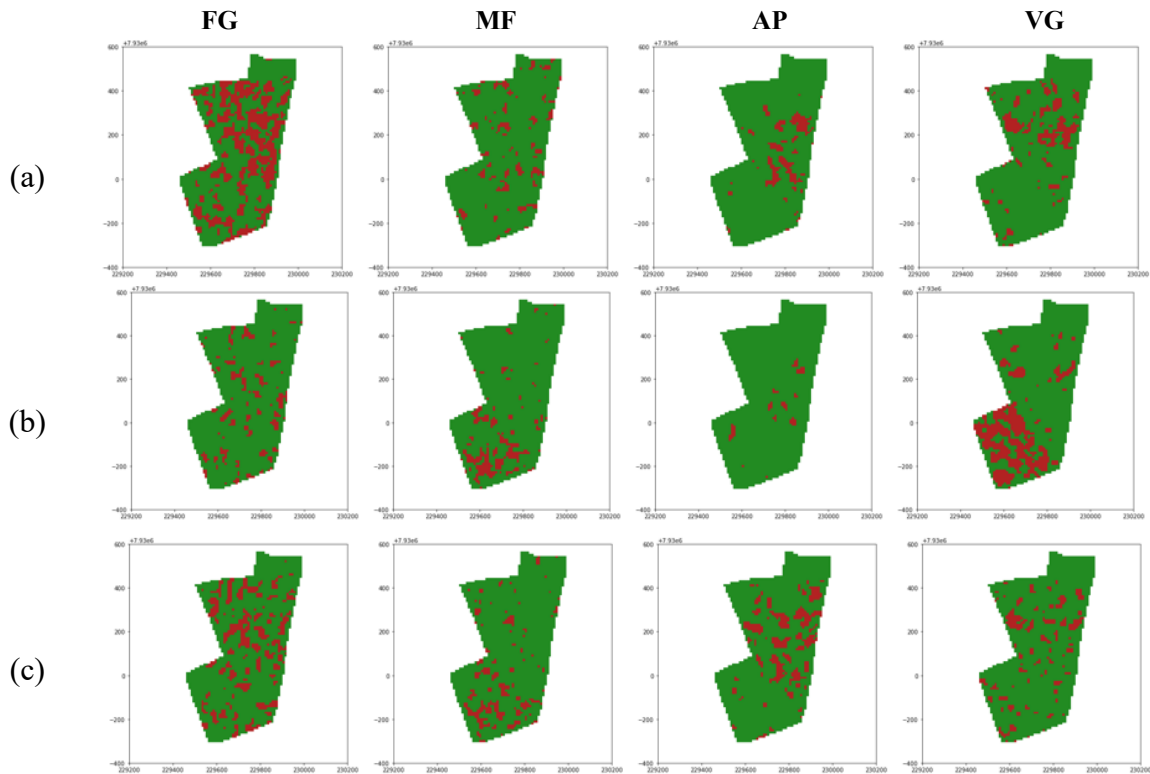
**Tabela 22** – Valores de F-Score obtidos para a combinação de atributos SAR. S representa a classe sadio e I representa a classe infestado. O gradiente de cores indica os valores da métrica F-Score em ordem decrescente.

| Fases            | FG   |      | MF   |      | AP   |      | VG   |      |
|------------------|------|------|------|------|------|------|------|------|
|                  | S    | I    | S    | I    | S    | I    | S    | I    |
| $\sigma^0VV$     | 0.9  | 0.54 | 0.93 | 0.74 | 0.89 | 0.47 | 0.89 | 0.58 |
| $\sigma^0VH$     | 0.9  | 0.68 | 0.94 | 0.82 | 0.87 | 0.30 | 0.88 | 0.51 |
| $\text{sumVVVH}$ | 0.91 | 0.63 | 0.96 | 0.84 | 0.89 | 0.45 | 0.9  | 0.54 |

Fonte: Elaborado pelo autor.

A Figura 52 apresenta os mapas da classificação considerando cada uma das combinações de atributos apresentadas na Tabela 22. De modo geral, as classificações considerando as fases fenológicas foram, similares àquelas geradas no Cenário 1 (Figura 48).

**Figura 52** – Distribuição espacial de áreas infestadas por nematoides a partir de dados ópticos: (a)  $\sigma^0VV$ , (b)  $\sigma^0VH$  e (c) sumVVVH. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



Fonte: Elaborado pelo autor.

Como pode ser observado, a fase FG apresenta a maior proporção de áreas detectadas como infestadas, principalmente ao considerar a polarização  $\sigma^0VV$  (Figura 52a). Em contrapartida, ao verificar os resultados do treinamento da rede (Tabela 22), verifica-se que a polarização  $\sigma^0VV$  foi a que forneceu menor valor de F-Score para a classe infestado na fase FG. A classe MF foi a que forneceu os maiores valores de F-Score durante o treinamento da rede, em contrapartida, foi a que detectou o menor percentual de áreas infestadas (Figura 52a, Figura 52b e Figura 52c). Em linhas gerais, percebe-se que a partir da polarização  $\sigma^0VV$  detecta-se mais áreas infestadas do que na polarização  $\sigma^0VH$ .

As Tabelas 23, 24 e 25 apresentam os resultados da classificação considerando a combinação de atributos ópticos e SAR para cada fase fenológica. Em verde é destacado melhora ao integrar dados SAR, em vermelho é destacado piora ao adicionar dados SAR na classificação e em azul é destacado a não alteração nos valores da métrica F-Score.

**Tabela 23** - F-Score para as combinações de atributos ópticos e a polarização  $\sigma^0VV$ .

| Atributos | FG   |      | MF   |      | AP   |      | VG   |      |
|-----------|------|------|------|------|------|------|------|------|
|           | S    | I    | S    | I    | S    | I    | S    | I    |
| VIS       | 0.99 | 0.97 | 0.98 | 0.95 | 0.96 | 0.85 | 0.98 | 0.95 |
| VIS+NIR   | 0.99 | 0.97 | 0.98 | 0.95 | 0.97 | 0.89 | 0.99 | 0.96 |
| VIS+RED1  | 0.99 | 0.96 | 0.99 | 0.96 | 0.95 | 0.81 | 0.98 | 0.95 |
| VIS+RED2  | 0.98 | 0.95 | 1    | 0.99 | 0.95 | 0.81 | 0.98 | 0.94 |
| VIS+RED3  | 0.98 | 0.93 | 0.99 | 0.98 | 0.96 | 0.87 | 0.98 | 0.96 |
| VIS+RED4  | 0.99 | 0.98 | 0.99 | 0.96 | 0.95 | 0.80 | 0.98 | 0.94 |
| VIS+SWIR1 | 1    | 0.99 | 0.98 | 0.94 | 0.96 | 0.87 | 0.98 | 0.96 |
| VIS+SWIR2 | 0.98 | 0.95 | 1    | 0.99 | 0.97 | 0.89 | 0.98 | 0.95 |
| VIS+NDVI  | 0.99 | 0.97 | 0.98 | 0.94 | 0.95 | 0.81 | 0.98 | 0.94 |

Fonte: Elaborado pelo autor.

**Tabela 24** - F-Score para as combinações de atributos ópticos e a polarização  $\sigma^0VH$ .

| Atributos | FG   |      | MF   |      | AP   |      | VG   |      |
|-----------|------|------|------|------|------|------|------|------|
|           | S    | I    | S    | I    | S    | I    | S    | I    |
| VIS       | 0.98 | 0.95 | 1    | 0.99 | 0.96 | 0.86 | 0.97 | 0.91 |
| VIS+NIR   | 0.98 | 0.94 | 0.99 | 0.98 | 0.96 | 0.87 | 0.98 | 0.94 |
| VIS+RED1  | 0.99 | 0.96 | 0.99 | 0.97 | 0.94 | 0.78 | 0.98 | 0.95 |
| VIS+RED2  | 1    | 0.99 | 0.98 | 0.95 | 0.96 | 0.84 | 0.98 | 0.95 |
| VIS+RED3  | 0.98 | 0.95 | 1    | 0.99 | 0.96 | 0.87 | 0.98 | 0.95 |
| VIS+RED4  | 0.99 | 0.98 | 1    | 0.99 | 0.96 | 0.87 | 0.98 | 0.94 |
| VIS+SWIR1 | 0.99 | 0.96 | 1    | 0.99 | 0.96 | 0.87 | 0.97 | 0.89 |
| VIS+SWIR2 | 0.99 | 0.98 | 0.99 | 0.98 | 0.96 | 0.87 | 0.97 | 0.89 |
| VIS+NDVI  | 0.99 | 0.97 | 0.98 | 0.93 | 0.94 | 0.77 | 0.97 | 0.90 |

Fonte: Elaborado pelo autor.

**Tabela 25** - F-Score para as combinações de atributos ópticos e o atributo sumVVVH.

| Atributos | FG   |      | MF   |      | AP   |      | VG   |      |
|-----------|------|------|------|------|------|------|------|------|
|           | S    | I    | S    | I    | S    | I    | S    | I    |
| VIS       | 0.99 | 0.96 | 0.99 | 0.97 | 0.95 | 0.81 | 0.97 | 0.89 |
| VIS+NIR   | 0.97 | 0.92 | 1    | 0.99 | 0.96 | 0.86 | 0.97 | 0.89 |
| VIS+RED1  | 0.98 | 0.95 | 0.98 | 0.94 | 0.96 | 0.85 | 0.97 | 0.90 |
| VIS+RED2  | 0.98 | 0.94 | 0.99 | 0.98 | 0.96 | 0.85 | 0.96 | 0.88 |
| VIS+RED3  | 0.98 | 0.94 | 0.99 | 0.98 | 0.96 | 0.86 | 0.98 | 0.94 |
| VIS+RED4  | 0.99 | 0.98 | 0.99 | 0.97 | 0.96 | 0.86 | 0.97 | 0.89 |
| VIS+SWIR1 | 0.98 | 0.95 | 1    | 0.99 | 0.96 | 0.85 | 0.97 | 0.89 |
| VIS+SWIR2 | 0.99 | 0.97 | 0.98 | 0.93 | 0.95 | 0.83 | 0.97 | 0.93 |
| VIS+NDVI  | 0.97 | 0.92 | 1    | 0.99 | 0.94 | 0.76 | 0.96 | 0.85 |

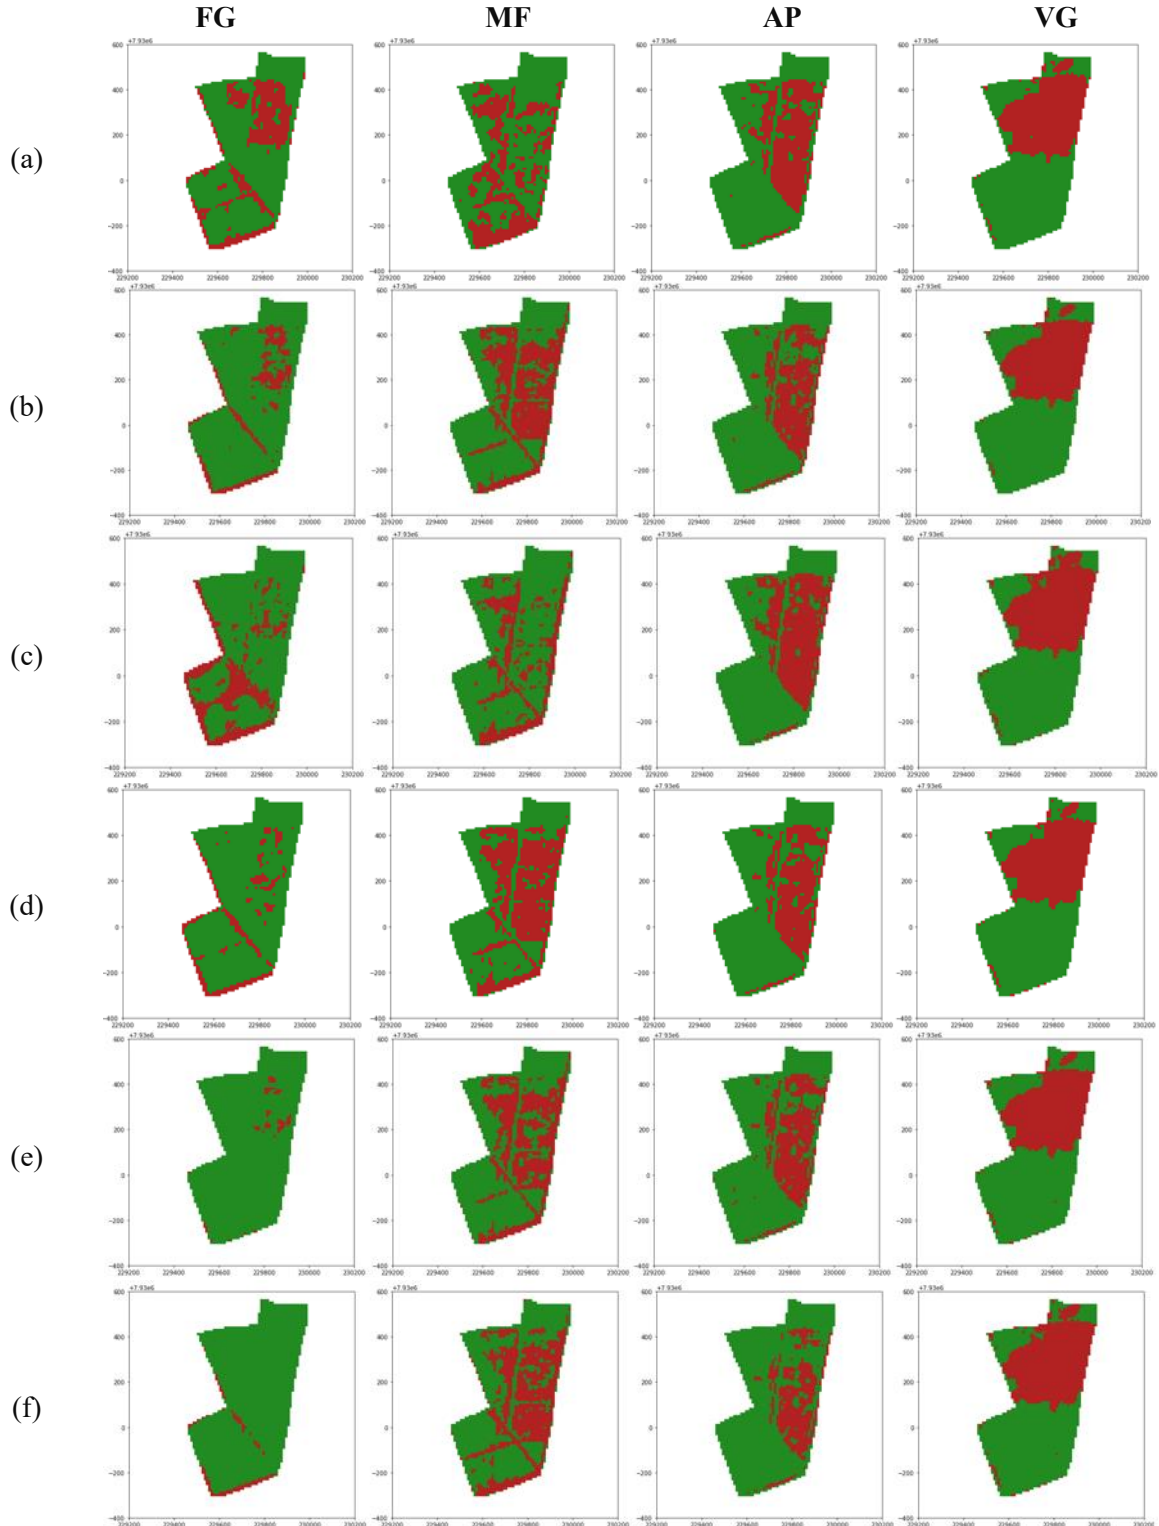
Fonte: Elaborado pelo autor.

Ao comparar os resultados das Tabelas 23, 24 e 25 aos apresentados na Tabela 21, nota-se que a utilização da polarização  $\sigma^0VV$  apresentou melhora em relação a combinação VIS+NDVI em todas as fases fenológicas, exceto na fase MF. Considerando a classe infestado, o aumento da métrica F-Score foi de 0,01 para a fase FG; 0,4 para a fase AP e 0,06 para a fase VG. Ainda nesse sentido, a polarização  $\sigma^0VH$  também demonstrou contribuição em todas as fases fenológicas ao inseri-lo na combinação de atributos VIS+RED, exceto na fase VG.

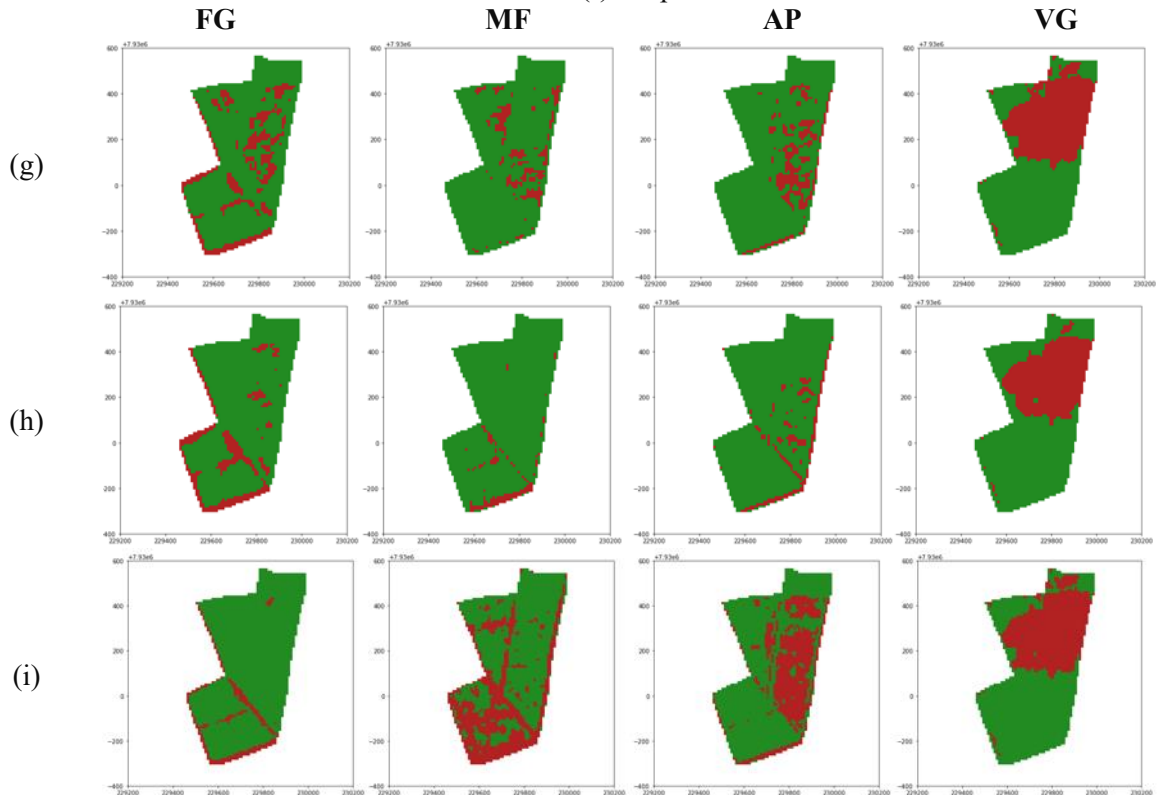
Na Figura 53 são apresentados os mapas da classificação considerando a combinação de atributos ópticos e a polarização  $\sigma^0VV$ . As demais classificações considerando as

combinações de atributos ópticos e SAR, por terem apresentado resultados similares aos obtidos a partir da polarização  $\sigma^0$ VV, são apresentadas na Figura 2 do Apêndice D.

**Figura 53** – Detecção de área infestada por nematoides a partir da combinação de dados ópticos e polarização  $\sigma^0$ VV: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



**Figura 53** – Detecção de área infestada por nematoides a partir da combinação de dados ópticos e polarização  $\sigma^0$ VV: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



Fonte: Elaborado pelo autor.

Comparando as classificações da Figura 52 e Figura 53, observa-se que a integração da polarização  $\sigma^0$ VV contribuiu para o aumento da detecção de áreas infestadas em todas as fases fenológicas, exceto a fase VG. Para esta fase, não é perceptível diferenças em relação as classificações que consideraram apenas atributos ópticos (Figura 52). Diferente dos resultados apresentados na Figura 52, as fases MF e AP apresentaram resultados similares para as combinações de atributos VIS+NIR, VIS+RED2, VIS+RED3 e VIS+RED4.

#### 4.2.4 Considerações sobre a utilização de rede BiLSTM para detecção de áreas infestadas por nematoides

Existem poucos estudos em sensoriamento remoto para detecção de nematoides na cultura cafeeira utilizando atributos SAR e métodos de aprendizado profundo, como as redes BiLSTM. Diante disso, este segundo experimento descreve a abordagem desenvolvida para o uso combinado de dados ópticos e SAR para detecção de nematoides, utilizando um modelo de rede BiLSTM. Devido ao desbalanceamento das amostras de treinamento, foi parametrizado

---

um modelo de rede que considerou a função de ativação *SparseCategoricalFocalLoss* e o critério *early stopping*.

Os atributos ópticos e SAR demonstraram resultados promissores em detectar áreas infestadas por nematoides. No entanto, ao se utilizar somente atributos SAR, o desempenho do modelo, avaliado para uma área de referência, foi consideravelmente menor. Os resultados das análises realizadas neste experimento demonstram que:

- Na Seção 4.2.3.1, considerando o Cenário 1, tem-se que as métricas de desempenho do treinamento da rede BiLSTM foram menores no caso de séries temporais muito curtas, como 12 e 24 meses, tanto para os atributos ópticos quanto para os atributos SAR. No Cenário 2 (Seção 4.2.3.2), os melhores resultados foram obtidos com as fases FG e MF, especialmente, a partir das combinações de atributos VIS+RED1 e VIS+SWIR2, respectivamente. Ao utilizar somente atributos SAR, a fase MF foi a que apresentou os melhores resultados, especialmente a partir da polarização  $\sigma^0$ VH.
- Quanto a detecção de nematoides na área teste considerando o Cenário 1 (Seção 4.2.3.3), houve maior detecção de áreas infestadas mais extensas e contínuas em séries temporais mais curtas, tanto para as combinações de atributos ópticos, quanto para as combinações que integravam dados ópticos e SAR. À medida que imagens de 2020 e 2021 foram incluídas nas séries temporais de atributos ópticos, houve uma redução drástica na detecção de áreas infestadas. Quando utilizados somente atributos SAR, foram detectadas áreas menores e mais fragmentadas nas séries temporais mais longas, sugerindo a necessidade de sequência de dados maiores para essa detecção.
- Ao se utilizar apenas as fases fenológicas específicas na construção das séries temporais (Cenário 2, Seção 4.2.3.4), verifica-se que os atributos ópticos detectam áreas infestadas maiores e contínuas, similares ao que é detectado nas séries temporais curtas do Cenário 1, exclusivamente para o caso da fase vegetativa (VG). Nas demais fases fenológicas, os carregadores foram interpretados como áreas infestadas na classificação a partir dos dados ópticos, indicando que a variação na densidade da vegetação fotossinteticamente ativa determinou a discriminação entre vegetação sadia e infestada.
- Ao se utilizar somente fases fenológicas específicas (Cenário 2) foi possível obter resultados comparáveis ao se utilizar séries temporais anuais (Cenário 1).

---

Ao analisar os valores de acurácia do treinamento para experimentos que consideraram o mesmo tipo de atributos (ópticos, SAR ou a combinação deles) nota-se que os valores de acurácia foram similares, como é o caso das combinações VIS +RED2,  $\sigma^0$ VV e  $\sigma^0$ VH para as fase FG e MF. Os fatos aqui apontados indicam a possibilidade da utilização de recortes temporais dos atributos, coincidentes com as fases fenológicas. A possibilidade de utilizar fases fenológicas específicas em detrimento de séries anuais, faz com que o método seja mais flexível, contornando as limitações da aquisição dos dados em regiões com alta cobertura de nuvens, por exemplo. A fase MF, por exemplo, ocorre em meses com baixa precipitação (abril, maio, junho), quando comparado com outros períodos do ano.

- Os atributos SAR individuais detectaram áreas infestadas em maior número e menor dimensão, sugerindo um padrão de pequenas reboleiras, coincidentes com a detecção realizada pelas séries temporais longas do Cenário 1 (Figura 50), nas fases de maturação de frutos (MF) e autopoda (AP). A definição dessas fases fenológicas como mais adequadas para detecção de áreas infestadas a partir de dados SAR corrobora a influência da estrutura da vegetação no sinal de micro-ondas na banda C.
- Destaca-se que não foram consideradas combinações de séries temporais de atributos SAR na classificação, os quais foram usados apenas individualmente ou em combinação com atributos ópticos. As combinações realizadas incrementaram a detecção de áreas infestadas por nematoides nas fases MF e AP, porém os carregadores foram associados às áreas infestadas, principalmente na fase MF.

### 4.3 Análise comparativa entre os experimentos

O Experimento 1 (Seção 4.1) teve por objetivo avaliar a contribuição de atributos extraídos das séries temporais de atributos ópticos e SAR na discriminação de áreas infestadas por nematoides, bem como identificar as fases fenológicas que favoreçam essa detecção. Essas análises foram realizadas a partir de testes estatísticos e análise de importância de atributos. No Experimento 2 (Seção 4.2), foi avaliada a capacidade de redes BiLSTM na detecção de nematoides, em uma área teste, a partir de dois cenários experimentais.

---

No Experimento 1, a análise de separabilidade indica que atributos na região do *red-edge* e SWIR são capazes de discriminar áreas infestadas por nematoides. Na análise de importância, estes também foram os que apresentaram os maiores valores SHAP. Nas fases de maturação dos frutos e autopoda o atributo B7 (*red-edge 3*) foi o de maior importância. Para as fases de formação dos grãos e vegetativa, o atributo B12 (SWIR2) foi o que apresentou os maiores valores de SHAP. Esse resultado é similar ao observado no Cenário 1 do Experimento 2 (Seção 4.2.3.1), no qual as combinações de atributos que envolviam os atributos na região do SWIR (VIS+SWIR1 e VIS+SWIR2) também foram os que apresentaram os melhores resultados, para todos os comprimentos de série temporal, exceto para a de 12 meses. No Cenário 2 do Experimento 2 (Seção 4.2.3.2), no qual foi considerado as informações de cada fase fenológica, a combinação de atributos VIS+SWIR2 também foi a que apresentou os maiores valores de *recall* ( $recall_s = 0,98$  e  $recall_l = 0,99$ ) para a fase de formação dos grãos.

Em relação aos atributos SAR, a polarização  $\sigma^0VV$  apresentou significância estatística em todas as fases fenológicas (Seção 4.1.3.2), exceto na fase de maturação dos frutos em 2017. Na análise de importância (Seção 4.1.3.3), a polarização  $\sigma^0VV$  também aparece como a de maior relevância em todas as fases fenológicas, com exceção da fase de formação dos grãos. No Cenário 1 do Experimento 2 (Seção 4.2.3.1), também se tem a polarização  $\sigma^0VV$  com os maiores valores de *recall*, para a classe infestado, exceto para a série temporal de 36 meses. No Cenário 2 do Experimento 2 (Seção 4.2.3.2), por sua vez, foi a polarização  $\sigma^0VH$  a que demonstrou melhor desempenho (*recall*) para as fases de formação dos grãos e maturação dos frutos. Já para as fases de autopoda e vegetativo foi a polarização  $\sigma^0VV$  que apresentou os melhores resultados.

Quando se compara visualmente as classificações geradas para o Cenário 1 e 2, obteve-se resultados similares, principalmente, ao considerar as séries temporais dos atributos SAR maiores que 24 meses e as séries temporais para as fases FG e MF. Ao utilizar somente os atributos ópticos, resultados semelhantes foram observados para as séries temporais da fase VG e as séries temporais menores que 36 meses.

---

## Capítulo 5

### CONCLUSÃO E RECOMENDAÇÕES

Esta tese descreve um estudo desenvolvido para investigar o potencial de séries temporais de atributos ópticos e SAR na discriminação de áreas infestadas por nematoides na cultura cafeeira, considerando a seguinte hipótese: “*Séries temporais de atributos ópticos e SAR permitem a discriminação de áreas infestadas por nematoides, em fases fenológicas específicas do ciclo de desenvolvimento do cafeeiro*”. Para isso, os seguintes objetivos foram delineados: caracterizar os padrões fenológicos do cafeeiro sadio e infestado por nematoides; avaliar a contribuição de atributos extraídos das séries temporais de atributos ópticos e SAR na detecção de nematoides, e identificar as fases fenológicas que favoreçam essa detecção e; avaliar a capacidade de redes BiLSTM na detecção de áreas infestadas por nematoides.

A abordagem adotada constou de uma sequência de etapas que buscou, inicialmente, compreender o comportamento temporal das áreas de cultivo de café, a partir de séries temporais de atributos ópticos e SAR ao longo de cinco anos. Posteriormente, foram investigados indicadores estatísticos (média e variância) que permitissem uma melhor caracterização de talhões sadios e infestados por nematoides, considerando cada fase fenológica. Na sequência, o conjunto de atributos ópticos e SAR foi avaliado individualmente, com o intuito de determinar aqueles mais relevantes para detecção de áreas infestadas, além do período mais propício para essa discriminação. Por fim, um modelo de rede BiLSTM foi ajustado e aplicado na detecção espaço-temporal de áreas infestadas por nematoides.

A utilização de dados ópticos para o monitoramento agrícola em regiões tropicais ainda é um desafio, muito devido a disponibilidade de imagens sem interferência de nuvens durante todo o ano. Diante disso, foi desenvolvida uma metodologia que combina dados do espectro de micro-ondas e dados ópticos. Esta abordagem, além de minimizar as limitações dos dados ópticos quanto à aquisição em condições atmosféricas adversas, propõe-se a discriminar áreas cafeeiras infestadas por nematoides. Além disso, é proposta uma análise no domínio temporal com o intuito de obter informações importantes no que diz respeito ao comportamento da cultura agrícola ao longo do seu ciclo de desenvolvimento, permitindo identificar as fases fenológicas com maior potencial de discriminação entre o cafeeiro sadio e o cafeeiro infestado por nematoides. Outro ponto importante da metodologia, é que a solução pode ser escalonável para outras culturas agrícolas e doenças/patógenos. No mais, a utilização da informação temporal amplia a possibilidade de novos estudos no contexto da empregabilidade de algoritmos de *deep*

---

*learning* em aplicações que envolvem o monitoramento de patógenos e doenças em culturas agrícolas.

Os resultados obtidos a partir dos experimentos realizados demonstram que:

- O comportamento temporal de atributos ópticos e SAR de talhões infestados por nematoides apresentam padrões e características que os diferenciam de talhões saudáveis, sendo possível identificar períodos em que a separabilidade entre áreas saudáveis e infestadas é mais evidente.
- As séries temporais dos atributos SAR permitiram a discriminação entre talhões saudáveis e infestados por nematoides, capturando adequadamente o comportamento sazonal da cultura. Diferente das séries temporais de atributos ópticos, cuja regularidade depende de uma interpolação nas datas com imagens faltantes, quando a aquisição é inviabilizada pelas condições atmosféricas, as imagens SAR permitem a construção de séries temporais regulares e densas, o que as tornam promissoras para o monitoramento de áreas infestadas.
- Quanto a utilização de métricas estatísticas, média e variância, a primeira demonstrou resultados satisfatórios para construção de séries temporais de conjuntos de pixels representativos de áreas saudáveis e infestadas, tanto para os dados ópticos quanto para os dados SAR.
- Considerando o descritor média, os atributos ópticos referentes à resposta espectral nas regiões do *red-edge* e SWIR (B11 e B12) e a polarizações  $\sigma^{0VV}$  demonstraram ser capazes de discriminar áreas infestadas por nematoides. Além dos atributos mais relevantes, a análise de importância indica as fases de maturação dos frutos e autopoda como as mais apropriadas na discriminação de áreas saudáveis e infestadas.
- A arquitetura da rede profunda BiLSTM mostrou-se adequada para a detecção de áreas infestadas por nematoides a partir das séries temporais. No entanto, foi observado que as métricas de desempenho da rede foram menores no caso de séries temporais muito curtas, como 12 e 24 meses. Ao considerar fases fenológicas específicas, a fase de maturação dos frutos foi a que apresentou os melhores resultados.

A partir dos apontamentos mencionados anteriormente conclui-se que a hipótese desta pesquisa é válida, visto que foram encontradas evidências da separabilidade dos alvos de interesse, tanto para séries temporais de atributos ópticos quanto para atributos SAR. Além disso, também se obteve resultados promissores para os experimentos que exploraram a

---

potencialidade da separação de áreas saudas e infestadas por nematoides em fases fenológicas específicas. Confrontando a detecção mais pontual obtida com atributos SAR, com a variação na vegetação dos talhões teste, infere-se que foram detectadas como áreas infestadas aquelas com maior comprometimento na estrutura da vegetação, ou seja, severamente infestadas.

Como recomendações para trabalhos futuros, sugere-se:

- Testar a metodologia proposta em outras áreas infestadas por nematoides, com referências de campo obtidas a partir da análise laboratorial do solo, além de considerar um intervalo temporal maior que o avaliado neste estudo.
- Avaliar outros algoritmos para interpolação de dados faltantes em séries temporais de atributos ópticos. Para isso, sugere-se algoritmos que consideram o contexto temporal, espacial e/ou espectral dos dados. Nesta pesquisa foi observado que mesmo após a utilização dos algoritmos Savitzky–Golay e *spline*, as séries temporais de atributos ópticos apresentaram *outliers*.
- Avaliar os modelos LSTM para a classificação de combinações de séries temporais de múltiplos atributos SAR, incorporando índices polarimétricos que explorem a informação de textura definida pela estrutura da vegetação, como é o caso de métricas resultantes da decomposição polarimétrica.
- Testar outros algoritmos de *deep learning* para detecção de áreas infestadas, tais como as redes *Gated Recurrent Units* (GRU). As redes GRU se diferenciam das redes LSTM por permitirem capturar adaptativamente dependências de grandes sequências de dados sem descartar informações de partes anteriores da série temporal.
- Realizar testes nematológicos nas áreas detectadas como infestadas e, se possível, associar o grau de infestação a capacidade de detecção dos algoritmos de *deep learning*.

---

## REFERÊNCIAS

AGRAWAL, S.; KHAIRNAR, G. B. A Comparative Assessment of Remote Sensing Imaging Techniques: Optical, SAR and Lidar. **ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, [S. l.], v. XLII-5/W3, p. 1–6, 2019. DOI: 10.5194/isprs-archives-XLII-5-W3-1-2019.

AKBARI, Elahe; DARVISHI BOLOORANI, Ali; NEYSANI SAMANY, Najmeh; HAMZEH, Saeid; SOUFIZADEH, Saeid; PIGNATTI, Stefano. Crop Mapping Using Random Forest and Particle Swarm Optimization based on Multi-Temporal Sentinel-2. **Remote Sensing**, [S. l.], v. 12, n. 9, p. 1449, 2020. DOI: 10.3390/rs12091449. Disponível em: <https://www.mdpi.com/2072-4292/12/9/1449>. Acesso em: 8 jul. 2020.

ALEBELE, Yeshanbele; ZHANG, Xue; WANG, Wenhui; YANG, Gaoxiang; YAO, Xia; ZHENG, Hengbiao; ZHU, Yan; CAO, Weixing; CHENG, Tao. Estimation of Canopy Biomass Components in Paddy Rice from Combined Optical and SAR Data Using Multi-Target Gaussian Regressor Stacking. **Remote Sensing**, [S. l.], v. 12, n. 16, p. 2564, 2020. DOI: 10.3390/rs12162564. Disponível em: <https://www.mdpi.com/2072-4292/12/16/2564>. Acesso em: 25 ago. 2020.

ALI, Kamran; JOHNSON, Brian A. Land-Use and Land-Cover Classification in Semi-Arid Areas from Medium-Resolution Remote-Sensing Imagery: A Deep Learning Approach. **Sensors**, [S. l.], v. 22, n. 22, p. 8750, 2022. DOI: 10.3390/s22228750.

AMARASINGAM, Narmilan; GONZALEZ, Felipe; SALGADOE, Arachchige Surantha Ashan; SANDINO, Juan; POWELL, Kevin. Detection of White Leaf Disease in Sugarcane Crops Using UAV-Derived RGB Imagery with Existing Deep Learning Models. **Remote Sensing**, [S. l.], v. 14, n. 23, p. 6137, 2022. DOI: 10.3390/rs14236137.

ARIAS, S. B. **Using Image Analysis and GIS for Coffee Mapping**. [s.l.] : McGill University Libraries, 2007. Disponível em: <https://books.google.com.br/books?id=xcjtoQEACAAJ>.

ARVOR, Damien; JONATHAN, Milton; MEIRELLES, Margareth Simões Penello; DUBREUIL, Vincent; DURIEUX, Laurent. Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil. **International Journal of Remote Sensing**, [S. l.], v. 32, n. 22, p. 7847–7871, 2011. DOI: 10.1080/01431161.2010.531783. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431161.2010.531783>. Acesso em: 26 ago. 2020.

BARATA, Rafael Alexandre Pena *et al.*, Evaluation of Coffee Plants Transplanted to an Area with Surface and Deep Liming Based on Multispectral Indices Acquired Using Unmanned Aerial Vehicles. **Agronomy**, [S. l.], v. 13, n. 10, p. 2623, 2023. DOI: 10.3390/agronomy13102623.

BARBOSA, Brenon Diennavam Souza; ARAÚJO E SILVA FERRAZ, Gabriel; MENDES DOS SANTOS, Luana; SANTANA, Lucas Santos; BEDIN MARIN, Diego; ROSSI, Giuseppe; CONTI, Leonardo. Application of RGB Images Obtained by UAV in Coffee Farming. **Remote Sensing**, [S. l.], v. 13, n. 12, p. 2397, 2021. DOI: 10.3390/rs13122397.

BEHMANN, Jan; MAHLEIN, Anne-Katrin; RUMPF, Till; RÖMER, Christoph; PLÜMER, Lutz. A review of advanced machine learning methods for the detection of biotic stress in

---

precision crop protection. **Precision Agriculture**, [S. l.], v. 16, n. 3, p. 239–260, 2015. DOI: 10.1007/s11119-014-9372-7. Disponível em: <http://link.springer.com/10.1007/s11119-014-9372-7>. Acesso em: 27 ago. 2020.

BENTO, Nicole Lopes; FERRAZ, Gabriel Araújo e Silva; AMORIM, Jhones da Silva; SANTANA, Lucas Santos; BARATA, Rafael Alexandre Pena; SOARES, Daniel Veiga; FERRAZ, Patrícia Ferreira Ponciano. Weed Detection and Mapping of a Coffee Farm by a Remotely Piloted Aircraft System. **Agronomy**, [S. l.], v. 13, n. 3, p. 830, 2023. DOI: 10.3390/agronomy13030830.

BERGER, Katja *et al.*, Multi-sensor spectral synergies for crop stress detection and monitoring in the optical domain: A review. **Remote Sensing of Environment**, [S. l.], v. 280, p. 113198, 2022. DOI: 10.1016/j.rse.2022.113198.

BI, Luning; HU, Guiping; RAZA, Muhammad Mohsin; KANDEL, Yuba; LEANDRO, Leonor; MUELLER, Daren. A Gated Recurrent Units (GRU)-Based Model for Early Detection of Soybean Sudden Death Syndrome through Time-Series Satellite Imagery. **Remote Sensing**, [S. l.], v. 12, n. 21, p. 3621, 2020. DOI: 10.3390/rs12213621.

BOUGUETTAYA, Abdelmalek; ZARZOUR, Hafed; KECHIDA, Ahmed; TABERKIT, Amine Mohammed. A survey on deep learning-based identification of plant and crop diseases from UAV-based aerial images. **Cluster Computing**, [S. l.], v. 26, n. 2, p. 1297–1317, 2023. DOI: 10.1007/s10586-022-03627-x.

BOURBIGOT, Matthieu. Sentinel-1 Product Definition. [S. l.], 2016.

BOUVET, A.; LE TOAN, T.; NGUYEN LAM-DAO. Monitoring of the Rice Cropping System in the Mekong Delta Using ENVISAT/ASAR Dual Polarization Data. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 47, n. 2, p. 517–526, 2009. DOI: 10.1109/TGRS.2008.2007963. Disponível em: <http://ieeexplore.ieee.org/document/4768722/>. Acesso em: 17 ago. 2020.

BROWN, Morton B.; FORSYTHE, Alan B. Robust Tests for the Equality of Variances. **Journal of the American Statistical Association**, [S. l.], v. 69, n. 346, p. 364–367, 1974. DOI: 10.1080/01621459.1974.10482955.

CAMARGO, Ângelo Paes De. As oito fases fenológicas da frutificação do cafeeiro. *Em*: 1998, Poços de Caldas. **Anais [...]**. *Em*: CONGRESSO BRASILEIRO DE PESQUISAS CAFEEIRAS. Poços de Caldas: Instituto Brasileiro do Café, 1998. p. 41–42.

CAMARGO, Ângelo Paes De; CAMARGO, Marcelo Bento Paes De. Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil. **Bragantia**, [S. l.], v. 60, n. 1, p. 65–68, 2001. DOI: 10.1590/S0006-87052001000100008. Disponível em: [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0006-87052001000100008&lng=pt&tlng=pt](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0006-87052001000100008&lng=pt&tlng=pt). Acesso em: 16 jan. 2020.

CAMPBELL, James B.; WYNNE, Randolph H. **Introduction to remote sensing**. 5th ed ed. New York: Guilford Press, 2011.

CAO, Ruyin; CHEN, Yang; SHEN, Miaogen; CHEN, Jin; ZHOU, Ji; WANG, Cong; YANG, Wei. A simple method to improve the quality of NDVI time-series data by integrating

---

spatiotemporal information with the Savitzky-Golay filter. **Remote Sensing of Environment**, [S. l.], v. 217, p. 244–257, 2018. DOI: 10.1016/j.rse.2018.08.022.

CARNEIRO, F. A. **Espécies de Meloidogyne Goeldi em Cafeeiro no Município De Araguari-Mg**. 2017. Dissertação de mestrado - Universidade Estadual Paulista, Jaboticabal, 2017. Acesso em: 16 jan. 2020.

CARVALHO, Carlos Henrique Siqueira De. **Cultivares de café**. Varginha, MG: EMBRAPA, 2008.

CHAKRABORTY, M.; MANJUNATH, K. R.; PANIGRAHY, S.; KUNDU, N.; PARIHAR, J. S. Rice crop parameter retrieval using multi-temporal, multi-incidence angle Radarsat SAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 59, n. 5, p. 310–322, 2005. DOI: 10.1016/j.isprsjprs.2005.05.001. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0924271605000407>. Acesso em: 17 ago. 2020.

CHARBONNEAU, F.; TRUDEL, M.; FERNANDES, R. Use of Dual Polarization and Multi-Incidence SAR for soil permeability mapping. **Use of Dual Polarization and Multi-Incidence SAR for soil permeability mapping**, [S. l.], v. 15, n. 17, 2005.

CHEMURA, Abel; MUTANGA, Onisimo; DUBE, Timothy. Integrating age in the detection and mapping of incongruous patches in coffee ( *Coffea arabica* ) plantations using multi-temporal Landsat 8 NDVI anomalies. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 57, p. 1–13, 2017. a. DOI: 10.1016/j.jag.2016.12.007. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243416302057>. Acesso em: 31 ago. 2020.

CHEMURA, Abel; MUTANGA, Onisimo; DUBE, Timothy. Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. **Precision Agriculture**, [S. l.], v. 18, n. 5, p. 859–881, 2017. b. DOI: 10.1007/s11119-016-9495-0. Disponível em: <http://link.springer.com/10.1007/s11119-016-9495-0>. Acesso em: 8 jul. 2020.

CHEMURA, Abel; MUTANGA, Onisimo; DUBE, Timothy. Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. **Precision Agriculture**, [S. l.], v. 18, n. 5, p. 859–881, 2017. c. DOI: 10.1007/s11119-016-9495-0.

CHEMURA, Abel; MUTANGA, Onisimo; SIBANDA, Mbulisi; CHIDOKO, Pardon. Machine learning prediction of coffee rust severity on leaves using spectroradiometer data. **Tropical Plant Pathology**, [S. l.], v. 43, n. 2, p. 117–127, 2018. DOI: 10.1007/s40858-017-0187-8. Disponível em: <http://link.springer.com/10.1007/s40858-017-0187-8>. Acesso em: 14 jul. 2020.

CHEN, Baili *et al.*, A joint learning Im-BiLSTM model for incomplete time-series Sentinel-2A data imputation and crop classification. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 108, p. 102762, 2022. DOI: 10.1016/j.jag.2022.102762.

CHEN, Jin; JÖNSSON, Per.; TAMURA, Masayuki; GU, Zhihui; MATSUSHITA, Bunkei; EKLUNDH, Lars. A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky–Golay filter. **Remote Sensing of Environment**, [S. l.], v. 91, n. 3, p. 332–344, 2004. DOI: 10.1016/j.rse.2004.03.014.

---

CHEN, Yang; CAO, Ruyin; CHEN, Jin; LIU, Licong; MATSUSHITA, Bunkei. A practical approach to reconstruct high-quality Landsat NDVI time-series data by gap filling and the Savitzky–Golay filter. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 180, p. 174–190, 2021. a. DOI: 10.1016/j.isprsjprs.2021.08.015.

CHEN, Yansi; HOU, Jinliang; HUANG, Chunlin; ZHANG, Ying; LI, Xianghua. Mapping Maize Area in Heterogeneous Agricultural Landscape with Multi-Temporal Sentinel-1 and Sentinel-2 Images Based on Random Forest. **Remote Sensing**, [S. l.], v. 13, n. 15, p. 2988, 2021. b. DOI: 10.3390/rs13152988.

CHERIF, Eya; HELL, Maximilian; BRANDMEIER, Melanie. DeepForest: Novel Deep Learning Models for Land Use and Land Cover Classification Using Multi-Temporal and -Modal Sentinel Data of the Amazon Basin. **Remote Sensing**, [S. l.], v. 14, n. 19, p. 5000, 2022. DOI: 10.3390/rs14195000.

CHLINGARYAN, Anna; SUKKARIEH, Salah; WHELAN, Brett. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. **Computers and Electronics in Agriculture**, [S. l.], v. 151, p. 61–69, 2018. DOI: 10.1016/j.compag.2018.05.012. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169917314710>. Acesso em: 27 ago. 2020.

CONAB. **Boletim da safra do café**. , 2022. Disponível em: <https://www.conab.gov.br/info-agro/safra/cafes/boletim-da-safra-de-caffe>. Acesso em: 16 out. 2021.

CORDERO-SANCHO, S.; SADER, S. A. Spectral analysis and classification accuracy of coffee crops using Landsat and a topographic-environmental model. **International Journal of Remote Sensing**, [S. l.], v. 28, n. 7, p. 1577–1593, 2007. DOI: 10.1080/01431160600887680. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01431160600887680>. Acesso em: 8 jul. 2020.

DAS, Shubhajyoti; BISWAS, Arindam; C, Vimalkumar; SINHA, Parimal. Deep Learning Analysis of Rice Blast Disease Using Remote Sensing Images. **IEEE Geoscience and Remote Sensing Letters**, [S. l.], v. 20, p. 1–5, 2023. DOI: 10.1109/LGRS.2023.3244324.

DE ALMEIDA, Luciana Florêncio; TARABAL, Juliano. Cerrado Mineiro Region D.O. Mark: Internationalization Strategy. **Proceedings in Food System Dynamics**, [S. l.], p. 133- 144 Pages, 2019. DOI: 10.18461/PFSD.2019.1913.

DE MULDER, Wim; BETHARD, Steven; MOENS, Marie-Francine. A survey on the application of recurrent neural networks to statistical language modeling. **Computer Speech & Language**, [S. l.], v. 30, n. 1, p. 61–98, 2015. DOI: 10.1016/j.csl.2014.09.005.

DEBELLA-GILO, Misganu; GJERTSEN, Arnt Kristian. Mapping Seasonal Agricultural Land Use Types Using Deep Learning on Sentinel-2 Image Time Series. **Remote Sensing**, [S. l.], v. 13, n. 2, p. 289, 2021. DOI: 10.3390/rs13020289.

DHAU, Inos; ADAM, Elhadi; AYISI, Kingsley K.; MUTANGA, Onesimo. Detection and mapping of maize streak virus using RapidEye satellite imagery. **Geocarto International**, [S. l.], v. 34, n. 8, p. 856–866, 2019. DOI: 10.1080/10106049.2018.1450448. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/10106049.2018.1450448>. Acesso em: 31 ago. 2020.

---

DO AMARAL, Elizabeth Santos; VIEIRA SILVA, Daniela; DOS ANJOS, Letícia; SCHILLING, Ana Cristina; DALMOLIN, Ândrea Carla; MIELKE, Marcelo Schramm. Relationships between reflectance and absorbance chlorophyll indices with RGB (Red, Green, Blue) image components in seedlings of tropical tree species at nursery stage. **New Forests**, [S. l.], v. 50, n. 3, p. 377–388, 2019. DOI: 10.1007/s11056-018-9662-4. Disponível em: <http://link.springer.com/10.1007/s11056-018-9662-4>. Acesso em: 31 ago. 2020.

EPIPHÂNIO, José Carlos Neves; LEONARDI, L.; FORMAGGIO, A. R. Relações entre parâmetros culturais e resposta espectral de cafezais. **Pesquisa Agropecuária Brasileira**, [S. l.], 1994. Disponível em: <https://www.semanticscholar.org/paper/Rela%C3%A7%C3%B5es-entre-par%C3%A2metros-culturais-e-resposta-de-Epiph%C3%A2nio-Leonardi/e62ad2004db507792d33b81c390ae1c4e7e85e41>. Acesso em: 3 jan. 2024.

EUROPEAN SPACE AGENCY. **User Guides - Sentinel Online**. [s.d.]. Disponível em: <https://copernicus.eu/user-guides>. Acesso em: 30 maio. 2023.

FARIFTEH, J.; VAN DER MEER, F.; ATZBERGER, C.; CARRANZA, E. J. M. Quantitative analysis of salt-affected soil reflectance spectra: A comparison of two adaptive methods (PLSR and ANN). **Remote Sensing of Environment**, [S. l.], v. 110, n. 1, p. 59–78, 2007. DOI: 10.1016/j.rse.2007.02.005. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S003442570700082X>. Acesso em: 26 ago. 2020.

FEDERAÇÃO DO CERRADO MINEIRO. **Região do Cerrado Mineiro. Região do Cerrado Mineiro**, 2023. Disponível em: <http://www.cerradomineiro.org/index.php>.

FELDERHOF, L.; GILLIESON, D. Near-infrared imagery from unmanned aerial systems and satellites can be used to specify fertilizer application rates in tree crops. **Canadian Journal of Remote Sensing**, [S. l.], v. 37, n. 4, p. 376–386, 2011. DOI: 10.5589/m11-046.

FERRÃO, Maria Amélia Gava; RIVA-SOUZA, Elaine Manelli. **Indicação de cultivares de café arábica para o estado do Espírito Santo e avaliação comparativa com o conilon em altitude elevada**. EMBRAPA, , 2021.

FILIPPONI, Federico. Sentinel-1 GRD Preprocessing Workflow. **Proceedings**, [S. l.], v. 18, n. 1, p. 11, 2019. DOI: 10.3390/ECRS-3-06201.

FRANKE, Jonas; MENZ, Gunter. Multi-temporal wheat disease detection by multi-spectral remote sensing. **Precision Agriculture**, [S. l.], v. 8, n. 3, p. 161–172, 2007. DOI: 10.1007/s11119-007-9036-y. Disponível em: <http://link.springer.com/10.1007/s11119-007-9036-y>. Acesso em: 29 ago. 2020.

GAO, Demin; SUN, Quan; HU, Bin; ZHANG, Shuo. A Framework for Agricultural Pest and Disease Monitoring Based on Internet-of-Things and Unmanned Aerial Vehicles. **Sensors**, [S. l.], v. 20, n. 5, p. 1487, 2020. DOI: 10.3390/s20051487. Disponível em: <https://www.mdpi.com/1424-8220/20/5/1487>. Acesso em: 25 ago. 2020.

GARCIA, Alvanir; COSTA, José Nilton Medeiros; RODRIGUES, Antonio Neri Azevedo. **Ocorrência e controle de nematoses do cafeeiro em Rondônia**. EMBRAPA, , 2000. Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/901836>.

---

GHINI, R.; HAMADA, E.; JÚNIOR, P.; JOSÉ, M.; MARENGO, J. A.; GONÇALVES, R. R. D. V. Risk analysis of climate change on coffee nematodes and leaf miner in Brazil. *[S. l.]*, v. 43, n. 2, p. 187–194, 2008.

GONZALEZ, Rafael C.; WOODS, Richard E. **Digital image processing**. 2nd ed ed. Upper Saddle River, N.J: Prentice Hall, 2002.

GRAVES, Alex. Long Short-Term Memory. *Em*: GRAVES, Alex (org.). **Supervised Sequence Labelling with Recurrent Neural Networks**. Studies in Computational Intelligence Berlin, Heidelberg: Springer, 2012. a. p. 37–45. DOI: 10.1007/978-3-642-24797-2\_4. Disponível em: [https://doi.org/10.1007/978-3-642-24797-2\\_4](https://doi.org/10.1007/978-3-642-24797-2_4). Acesso em: 12 jun. 2023.

GRAVES, Alex. **Supervised sequence labelling with recurrent neural networks**. Heidelberg ; New York: Springer, 2012. b.

GUMELAR, Ogi; DAWEI, Liu; RIZKIYANTO, Rahmat. Polarimetric Decomposition in Calibrated Radar Image for Detecting Vegetation Object. *Em*: 2017, **Anais [...]**. [s.l: s.n.]

HASHIM, Izrahayu Che; SHARIFF, Abdul Rashid Mohamed; BEJO, Siti Khairunniza; MUHARAM, Farrah Melissa; AHMAD, Khairulmazmi. Machine-Learning Approach Using SAR Data for the Classification of Oil Palm Trees That Are Non-Infected and Infected with the Basal Stem Rot Disease. **Agronomy**, *[S. l.]*, v. 11, n. 3, p. 532, 2021. DOI: 10.3390/agronomy11030532.

HERNÁNDEZ, Mercedes; BORGES, Andrés A.; FRANCISCO-BETHENCOURT, Desiderio. Mapping stressed wheat plants by soil aluminum effect using C-band SAR images: implications for plant growth and grain quality. **Precision Agriculture**, *[S. l.]*, v. 23, n. 3, p. 1072–1092, 2022. DOI: 10.1007/s11119-022-09875-6.

HINTON, Geoffrey E.; SRIVASTAVA, Nitish; KRIZHEVSKY, Alex; SUTSKEVER, Ilya; SALAKHUTDINOV, Ruslan R. Improving neural networks by preventing co-adaptation of feature detectors. *[S. l.]*, 2012. DOI: 10.48550/ARXIV.1207.0580. Disponível em: <https://arxiv.org/abs/1207.0580>. Acesso em: 16 out. 2023.

HORNERO, A.; HERNÁNDEZ-CLEMENTE, R.; NORTH, P. R. J.; BECK, P. S. A.; BOSCIA, D.; NAVAS-CORTES, J. A.; ZARCO-TEJADA, P. J. Monitoring the incidence of *Xylella fastidiosa* infection in olive orchards using ground-based evaluations, airborne imaging spectroscopy and Sentinel-2 time series through 3-D radiative transfer modelling. **Remote Sensing of Environment**, *[S. l.]*, v. 236, p. 111480, 2020. DOI: 10.1016/j.rse.2019.111480.

HUANG, Yanbo; CHEN, Zhong-xin; YU, Tao; HUANG, Xiang-zhi; GU, Xing-fa. Agricultural remote sensing big data: Management and applications. **Journal of Integrative Agriculture**, *[S. l.]*, v. 17, n. 9, p. 1915–1931, 2018. DOI: 10.1016/S2095-3119(17)61859-8. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2095311917618598>. Acesso em: 25 ago. 2020.

HUNT, David A.; TABOR, Karyn; HEWSON, Jennifer H.; WOOD, Margot A.; REYMONDIN, Louis; KOENIG, Kellee; SCHMITT-HARSH, Mikaela; FOLLETT, Forrest. Review of Remote Sensing Methods to Map Coffee Production Systems. **Remote Sensing**, *[S. l.]*, v. 12, n. 12, p. 2041, 2020. a. DOI: 10.3390/rs12122041.

---

HUNT, David A.; TABOR, Karyn; HEWSON, Jennifer H.; WOOD, Margot A.; REYMONDIN, Louis; KOENIG, Kellee; SCHMITT-HARSH, Mikaela; FOLLETT, Forrest. Review of Remote Sensing Methods to Map Coffee Production Systems. **Remote Sensing**, [S. l.], v. 12, n. 12, p. 2041, 2020. b. DOI: 10.3390/rs12122041. Disponível em: <https://www.mdpi.com/2072-4292/12/12/2041>. Acesso em: 14 jul. 2020.

IBGE. **Sistema IBGE de Recuperação Automática - SIDRA**. 2023. Disponível em: <https://sidra.ibge.gov.br/home/pnadct/minas-gerais>. Acesso em: 23 ago. 2023.

JENSEN, John R. **Remote sensing of the environment: an earth resource perspective**. Second edition [exclusive edition only for the benefit of students outside the United States and Canada] ed. Harlow: Pearson, 2014.

JING, Xia; ZOU, Qin; YAN, Jumei; DONG, Yingying; LI, Bingyu. Remote Sensing Monitoring of Winter Wheat Stripe Rust Based on mRMR-XGBoost Algorithm. **Remote Sensing**, [S. l.], v. 14, n. 3, p. 756, 2022. DOI: 10.3390/rs14030756.

JÖNSSON, Per; CAI, Zhazhang; MELAAS, Eli; FRIEDL, Mark; EKLUNDH, Lars. A Method for Robust Estimation of Vegetation Seasonality from Landsat and Sentinel-2 Time Series Data. **Remote Sensing**, [S. l.], v. 10, n. 4, p. 635, 2018. DOI: 10.3390/rs10040635. Disponível em: <http://www.mdpi.com/2072-4292/10/4/635>. Acesso em: 26 ago. 2020.

JÖNSSON, Per; EKLUNDH, Lars. TIMESAT—a program for analyzing time-series of satellite sensor data. **Computers & Geosciences**, [S. l.], v. 30, n. 8, p. 833–845, 2004. DOI: 10.1016/j.cageo.2004.05.006. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0098300404000974>. Acesso em: 26 ago. 2020.

KATSUHAMA, Naoya; IMAI, Masataka; NARUSE, Nobuyasu; TAKAHASHI, Yukihiro. Discrimination of areas infected with coffee leaf rust using a vegetation index. **Remote Sensing Letters**, [S. l.], v. 9, n. 12, p. 1186–1194, 2018. a. DOI: 10.1080/2150704X.2018.1519269. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/2150704X.2018.1519269>. Acesso em: 14 jul. 2020.

KATSUHAMA, Naoya; IMAI, Masataka; NARUSE, Nobuyasu; TAKAHASHI, Yukihiro. Discrimination of areas infected with coffee leaf rust using a vegetation index. **Remote Sensing Letters**, [S. l.], v. 9, n. 12, p. 1186–1194, 2018. b. DOI: 10.1080/2150704X.2018.1519269.

KAUL, Monisha; HILL, Robert L.; WALTHALL, Charles. Artificial neural networks for corn and soybean yield prediction. **Agricultural Systems**, [S. l.], v. 85, n. 1, p. 1–18, 2005. DOI: 10.1016/j.agsy.2004.07.009. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0308521X04001398>. Acesso em: 26 ago. 2020.

KINGMA, Diederik P.; BA, Jimmy. **Adam: A Method for Stochastic Optimization**. arXiv, , 2017. Disponível em: <http://arxiv.org/abs/1412.6980>. Acesso em: 16 out. 2023.

KLEIN, Herbert S.; LUNA, Francisco Vidal. **Brazilian Crops in the Global Market: The Emergence of Brazil as a World Agribusiness Exporter Since 1950**. [s.l.] : Springer Nature, 2023.

KOOPMANS, Lambert H. **The spectral analysis of time series**. 2nd ed. ed. San Diego: Academic Press, 1995.

---

LAKMAL, Dimuthu; KUGATHASAN, Kumaran; NANAYAKKARA, Vishaka; JAYASENA, Suranga; PERERA, Amal Shehan; FERNANDO, Lasantha. Brown Planthopper Damage Detection using Remote Sensing and Machine Learning. *Em: 2019 18TH IEEE INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND APPLICATIONS (ICMLA) 2019*, Boca Raton, FL, USA. **Anais [...]**. Boca Raton, FL, USA: IEEE, 2019. p. 97–104. DOI: 10.1109/ICMLA.2019.00024. Disponível em: <https://ieeexplore.ieee.org/document/8999114/>. Acesso em: 24 ago. 2020.

LARY, David J.; ALAVI, Amir H.; GANDOMI, Amir H.; WALKER, Annette L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, [S. l.], v. 7, n. 1, p. 3–10, 2016. DOI: 10.1016/j.gsf.2015.07.003.

LE TOAN, Thuy. **Introduction to SAR Remote Sensing**,. Lisbon, Portugal

LEMES, Ernane M.; MACHADO, Túlio V.; GONTIJO, Luciana N.; DE ANDRADE, Samuel L.; TORRES, José L. R.; SANTOS, Maria A.; COELHO, Lísias. Detection of rubber tree orchards infested by *Meloidogyne exigua* using vegetation indexes obtained from satellite images. **New Forests**, [S. l.], v. 51, n. 5, p. 765–779, 2020. DOI: 10.1007/s11056-019-09760-7. Disponível em: <http://link.springer.com/10.1007/s11056-019-09760-7>. Acesso em: 31 ago. 2020.

LI, Lu; DONG, Yingying; XIAO, Yingxin; LIU, Linyi; ZHAO, Xing; HUANG, Wenjiang. Combining Disease Mechanism and Machine Learning to Predict Wheat Fusarium Head Blight. **Remote Sensing**, [S. l.], v. 14, n. 12, p. 2732, 2022. DOI: 10.3390/rs14122732.

LI, Qianjing; TIAN, Jia; TIAN, Qingjiu. Deep Learning Application for Crop Classification via Multi-Temporal Remote Sensing Images. **Agriculture**, [S. l.], v. 13, n. 4, p. 906, 2023. DOI: 10.3390/agriculture13040906.

LI, Xuqing; LI, Long; LIU, Xiangnan. Collaborative inversion heavy metal stress in rice by using two-dimensional spectral feature space based on HJ-1 A HSI and radarsat-2 SAR remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 78, p. 39–52, 2019. DOI: 10.1016/j.jag.2018.12.011. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243417302921>. Acesso em: 24 ago. 2020.

LIAKOS, Konstantinos; BUSATO, Patrizia; MOSHOU, Dimitrios; PEARSON, Simon; BOCHTIS, Dionysis. Machine Learning in Agriculture: A Review. **Sensors**, [S. l.], v. 18, n. 8, p. 2674, 2018. DOI: 10.3390/s18082674. Disponível em: <http://www.mdpi.com/1424-8220/18/8/2674>. Acesso em: 26 ago. 2020.

LIN, Tsung-Yi; GOYAL, Priya; GIRSHICK, Ross; HE, Kaiming; DOLLÁR, Piotr. Focal Loss for Dense Object Detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [S. l.], v. 42, n. 2, p. 318–327, 2020. DOI: 10.1109/TPAMI.2018.2858826.

LIU, Chang-an; CHEN, Zhong-xin; SHAO, Yun; CHEN, Jin-song; HASI, Tuya; PAN, Hai-zhu. Research advances of SAR remote sensing for agriculture applications: A review. **Journal of Integrative Agriculture**, [S. l.], v. 18, n. 3, p. 506–525, 2019. DOI: 10.1016/S2095-3119(18)62016-7. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2095311918620167>. Acesso em: 17 ago. 2020.

---

LOUIS, Jérôme; DEBAECKER, Vincent; PFLUG, Bringfried; MAIN-KNORN, Magdalena; BIENIARZ, Jakub; MUELLER-WILM, Uwe; CADAU, Enrico; GASCON, Ferran. SENTINEL-2 SEN2COR: L2A PROCESSOR FOR USERS. *[S. l.]*, 2016.

LUNDBERG, Scott; LEE, Su-In. A Unified Approach to Interpreting Model Predictions. *[S. l.]*, 2017. DOI: 10.48550/ARXIV.1705.07874. Disponível em: <https://arxiv.org/abs/1705.07874>. Acesso em: 30 jun. 2022.

MANN, H. B.; WHITNEY, D. R. On a Test of Whether one of Two Random Variables is Stochastically Larger than the Other. **The Annals of Mathematical Statistics**, *[S. l.]*, v. 18, n. 1, p. 50–60, 1947. DOI: 10.1214/aoms/1177730491.

MARIN, Diego Bedin; DE CARVALHO ALVES, Marcelo; POZZA, Edson Ampélio; BELAN, Leônidas Leoni; DE OLIVEIRA FREITAS, Marcelo Loran. Multispectral radiometric monitoring of bacterial blight of coffee. **Precision Agriculture**, *[S. l.]*, v. 20, n. 5, p. 959–982, 2019. a. DOI: 10.1007/s11119-018-09623-9. Disponível em: <http://link.springer.com/10.1007/s11119-018-09623-9>. Acesso em: 14 jul. 2020.

MARIN, Diego Bedin; DE CARVALHO ALVES, Marcelo; POZZA, Edson Ampélio; BELAN, Leônidas Leoni; DE OLIVEIRA FREITAS, Marcelo Loran. Multispectral radiometric monitoring of bacterial blight of coffee. **Precision Agriculture**, *[S. l.]*, v. 20, n. 5, p. 959–982, 2019. b. DOI: 10.1007/s11119-018-09623-9.

MARTINELLI, Luiz A.; NAYLOR, Rosamond; VITOUSEK, Peter M.; MOUTINHO, Paulo. Agriculture in Brazil: impacts, costs, and opportunities for a sustainable future. **Current Opinion in Environmental Sustainability**, *[S. l.]*, v. 2, n. 5–6, p. 431–438, 2010. DOI: 10.1016/j.cosust.2010.09.008.

MARTINS, George Deroco; GALO, Maria de Lourdes Bueno Trindade; VIEIRA, Bruno Sergio. Detecting and Mapping Root-Knot Nematode Infection in Coffee Crop Using Remote Sensing Measurements. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, *[S. l.]*, v. 10, n. 12, p. 5395–5403, 2017. DOI: 10.1109/JSTARS.2017.2737618. Disponível em: <http://ieeexplore.ieee.org/document/8016326/>. Acesso em: 8 jul. 2020.

MASCOLO, Lucio; LOPEZ-SANCHEZ, Juan M.; CLOUDE, Shane R. Thermal Noise Removal From Polarimetric Sentinel-1 Data. **IEEE Geoscience and Remote Sensing Letters**, *[S. l.]*, v. 19, p. 1–5, 2022. DOI: 10.1109/LGRS.2021.3050921.

MEKETE, T.; SIKORA, R. A.; KIEWNICK, S.; HALLMANN, J. Description Of Plant Parasitic Nematodes Associated With Coffee In Ethiopia. *[S. l.]*, v. 36, p. 69–77, 2008.

MENDONÇA, R. F.; RODRIGUES, W. A.; LIMA, D. M.; TOMAZ, M. A. ABORDAGEM SOBRE A BIENALIDADE DE PRODUÇÃO EM PLANTAS DE CAFÉ. *[S. l.]*, v. 7, n. 13, p. 1–9, 2011.

MERCIER, Audrey *et al.*, Evaluation of Sentinel-1 and 2 Time Series for Land Cover Classification of Forest–Agriculture Mosaics in Temperate and Tropical Landscapes. **Remote Sensing**, *[S. l.]*, v. 11, n. 8, p. 979, 2019. DOI: 10.3390/rs11080979. Disponível em: <https://www.mdpi.com/2072-4292/11/8/979>. Acesso em: 9 jul. 2020.

---

MIRANDA, Jonathan da Rocha; ALVES, Marcelo de Carvalho; POZZA, Edson Ampélio; SANTOS NETO, Helon. Detection of coffee berry necrosis by digital image processing of landsat 8 oli satellite imagery. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 85, p. 101983, 2020. a. DOI: 10.1016/j.jag.2019.101983. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243419306853>. Acesso em: 14 jul. 2020.

MIRANDA, Jonathan da Rocha; ALVES, Marcelo de Carvalho; POZZA, Edson Ampélio; SANTOS NETO, Helon. Detection of coffee berry necrosis by digital image processing of landsat 8 oli satellite imagery. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 85, p. 101983, 2020. b. DOI: 10.1016/j.jag.2019.101983.

MORALES-ARANIBAR, Luis *et al.*, Ecological Interaction in the Proliferation of Phytoparasitic Nematodes in Coffee var. Typica. **Agronomy**, [S. l.], v. 13, n. 6, p. 1653, 2023. DOI: 10.3390/agronomy13061653.

MORAN, M. Susan; HYMER, Daniel C.; QI, Jiaguo; KERR, Yann. Comparison of ERS-2 SAR and Landsat TM imagery for monitoring agricultural crop and soil conditions. **Remote Sensing of Environment**, [S. l.], v. 79, n. 2–3, p. 243–252, 2002. DOI: 10.1016/S0034-4257(01)00276-0. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0034425701002760>. Acesso em: 31 ago. 2020.

NASIRZADEHDIZAJI, Rouhollah; BALIK SANLI, Fusun; ABDIKAN, Saygin; CAKIR, Ziyadin; SEKERTKIN, Aliihsan; USTUNER, Mustafa. Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. **Applied Sciences**, [S. l.], v. 9, n. 4, p. 655, 2019. DOI: 10.3390/app9040655.

NAVROZIDIS, Ioannis; ALEXANDRIDIS, Thomas; MOSHOU, Dimitrios; HAUGOMMARD, Anne; LAGOPODI, Anastasia. Implementing Sentinel-2 Data and Machine Learning to Detect Plant Stress in Olive Groves. **Remote Sensing**, [S. l.], v. 14, n. 23, p. 5947, 2022. DOI: 10.3390/rs14235947.

NEGRISOLI, Matheus Mereb; NEGRISOLI, RaphaelMereb; DA SILVA, FlavioNunes; LOPES, Lucasda Silva; SOUZA JÚNIOR, Franciscode Sales De; VELINI, Edivaldo Domingues; CARBONARI, Caio Antonio; RODRIGUES, Sergio Augusto; RAETANO, Carlos Gilberto. Soybean rust detection and disease severity classification by remote sensing. **Agronomy Journal**, [S. l.], v. 114, n. 6, p. 3246–3262, 2022. DOI: 10.1002/agj2.21152.

NOGUEIRA MARTINS, Rodrigo; DE CARVALHO PINTO, Francisco De Assis; MARÇAL DE QUEIROZ, Daniel; MAGALHÃES VALENTE, Domingos Sárvio; FIM ROSAS, Jorge Tadeu. A Novel Vegetation Index for Coffee Ripeness Monitoring Using Aerial Imagery. **Remote Sensing**, [S. l.], v. 13, n. 2, p. 263, 2021. DOI: 10.3390/rs13020263.

NOVO, Evlyn Márcia Leão de Moraes; PONZONI, Flávio Jorge. **Introdução ao Sensoriamento Remoto.** , 2001.

NYQUIST, H. Certain Topics in Telegraph Transmission Theory. **Transactions of the American Institute of Electrical Engineers**, [S. l.], v. 47, n. 2, p. 617–644, 1928. DOI: 10.1109/T-AIEE.1928.5055024.

---

OLIVEIRA, Claudio Marcelo Gonçalves De; ROSA, Juliana Magrinelli Osório Rosa. **Nematoides parasitos do cafeeiro**. São Paulo: Instituto Biológico, 2018.

ORTEGA, Antonio César; DE JESUS, Clesio Marcelino; MOURO, Marcela de Castro. Mecanização e Emprego na Cafeicultura do Cerrado Mineiro. **Revista da ABET**, [S. l.], v. 8, n. 2, 2009. Disponível em: <https://periodicos.ufpb.br/index.php/abet/article/view/15268>.

PEREIRA, Fernando Vasconcelos; MARTINS, George Deroco; VIEIRA, Bruno Sérgio; DE ASSIS, Gleice Aparecida; ORLANDO, Vinicius Silva Werneck. Multispectral images for monitoring the physiological parameters of coffee plants under different treatments against nematodes. **Precision Agriculture**, [S. l.], v. 23, n. 6, p. 2312–2344, 2022. DOI: 10.1007/s11119-022-09922-2.

PICOLI, Michelle Cristina Araujo *et al.*, Big earth observation time series analysis for monitoring Brazilian agriculture. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 145, p. 328–339, 2018. DOI: 10.1016/j.isprsjprs.2018.08.007.

PIERRE POTT, Luan; JORGE CARNEIRO AMADO, Telmo; AUGUSTO SCHWALBERT, Raí; MATEUS CORASSA, Geomar; ANTONIO CIAMPITTI, Ignacio. Crop type classification in Southern Brazil: Integrating remote sensing, crop modeling and machine learning. **Computers and Electronics in Agriculture**, [S. l.], v. 201, p. 107320, 2022. DOI: 10.1016/j.compag.2022.107320.

QUEGAN, S.; JIONG JIONG YU. Filtering of multichannel SAR images. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 39, n. 11, p. 2373–2379, 2001. DOI: 10.1109/36.964973.

RAHMAN, Muhammad Moshir; ROBSON, Andrew; BRINKHOFF, James. Potential of Time-Series Sentinel 2 Data for Monitoring Avocado Crop Phenology. **Remote Sensing**, [S. l.], v. 14, n. 23, p. 5942, 2022. DOI: 10.3390/rs14235942.

**Região do Cerrado Mineiro. EXPOCACER**, [s.d.]. Disponível em: <https://expocaccer.com.br/institucional/regiao-do-cerrado-mineiro/>. Acesso em: 2 nov. 2023.

SAAD EL IMANNI, Hajar; EL HARTI, Abderrazak; PANIMBOZA, Jonathan. Investigating Sentinel-1 and Sentinel-2 Data Efficiency in Studying the Temporal Behavior of Wheat Phenological Stages Using Google Earth Engine. **Agriculture**, [S. l.], v. 12, n. 10, p. 1605, 2022. DOI: 10.3390/agriculture12101605.

SALEHINEJAD, Hojjat; SANKAR, Sharan; BARFETT, Joseph; COLAK, Errol; VALAEE, Shahrokh. **Recent Advances in Recurrent Neural Networks**. arXiv, , 2018. Disponível em: <http://arxiv.org/abs/1801.01078>. Acesso em: 4 nov. 2023.

SALGADO, Sônia Maria de Lima; CARNEIRO, Regina Maria Dechechi Gomes; DE PINHO, Renata Silva Canuto. **Aspectos técnicos dos nematoides parasitas do cafeeiro**. EMPRESA DE PESQUISA AGROPECUÁRIA DE MINAS GERAIS (EPAMIG), , 2011.

SALGADO, Sônia Maria de Lima; CARNEIRO, Regina Maria Dechechi Gomes; PINHO, Renata Silva Canuto De. **Aspectos técnicos dos nematoides parasitas do cafeeiro**. Belo Horizonte: EPAMIG, 2011.

---

SANKARAN, Sindhuja; MISHRA, Ashish; EHSANI, Reza; DAVIS, Cristina. A review of advanced techniques for detecting plant diseases. **Computers and Electronics in Agriculture**, [S. l.], v. 72, n. 1, p. 1–13, 2010. DOI: 10.1016/j.compag.2010.02.007. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169910000438>. Acesso em: 14 jul. 2020.

SANTANA, Guilherme Henrique dos Santos. **Indicação geográfica (IG) do café do Cerrado Mineiro: dinâmicas e territorialidades**. 2022. Universidade Federal de Uberlândia, Uberlândia, 2022. Disponível em: <https://repositorio.ufu.br/handle/123456789/34984>. Acesso em: 2 nov. 2023.

SAVITZKY, Abraham.; GOLAY, M. J. E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. **Analytical Chemistry**, [S. l.], v. 36, n. 8, p. 1627–1639, 1964. DOI: 10.1021/ac60214a047.

SCHMITT-HARSH, Mikaela. Landscape change in Guatemala: Driving forces of forest and coffee agroforest expansion and contraction from 1990 to 2010. **Applied Geography**, [S. l.], v. 40, p. 40–50, 2013. DOI: 10.1016/j.apgeog.2013.01.007. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0143622813000349>. Acesso em: 25 ago. 2020.

SCHUSTER, M.; PALIWAL, K. K. Bidirectional recurrent neural networks. **IEEE Transactions on Signal Processing**, [S. l.], v. 45, n. 11, p. 2673–2681, 1997. DOI: 10.1109/78.650093.

SHI, Yue; HAN, Liangxiu; KLEEREKOPER, Anthony; CHANG, Sheng; HU, Tongle. Novel CropdocNet Model for Automated Potato Late Blight Disease Detection from Unmanned Aerial Vehicle-Based Hyperspectral Imagery. **Remote Sensing**, [S. l.], v. 14, n. 2, p. 396, 2022. DOI: 10.3390/rs14020396.

SILVA-PEREZ, Cristian; MARINO, Armando; LOPEZ-SANCHEZ, Juan M.; CAMERON, Iain. Multitemporal Polarimetric SAR Change Detection for Crop Monitoring and Crop Type Classification. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.], v. 14, p. 12361–12374, 2021. DOI: 10.1109/JSTARS.2021.3130186.

SINGH, D.; SAO, R.; SINGH, K. P. A remote sensing assessment of pest infestation on sorghum. **Advances in Space Research**, [S. l.], v. 39, n. 1, p. 155–163, 2007. DOI: 10.1016/j.asr.2006.02.025. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S027311770600086X>. Acesso em: 24 ago. 2020.

SOUDANI, Kamel; DELPIERRE, Nicolas; BERVEILLER, Daniel; HMIMINA, Gabriel; VINCENT, Gaëlle; MORFIN, Alexandre; DUFRÊNE, Éric. Potential of C-band Synthetic Aperture Radar Sentinel-1 time-series for the monitoring of phenological cycles in a deciduous forest. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 104, p. 102505, 2021. DOI: 10.1016/j.jag.2021.102505.

SOUZA, Carolina Gusmão; ARANTES, Tássia Borges; CARVALHO, Luis Marcelo Tavares De; AGUIAR, Polyanne. Multitemporal variables for the mapping of coffee cultivation areas. **Pesquisa Agropecuária Brasileira**, [S. l.], v. 54, p. e00017, 2019. DOI: 10.1590/s1678-3921.pab2019.v54.00017.

SREEDHAR, Rahul; VARSHNEY, Avnish; DHANYA, M. Sugarcane crop classification using time series analysis of optical and SAR sentinel images: a deep learning approach.

---

**Remote Sensing Letters**, [S. l.], v. 13, n. 8, p. 812–821, 2022. DOI: 10.1080/2150704X.2022.2088254.

TERRA, W. C.; SILVA, J. C. P. D.; CAMPOS, V. P.; SALGADO, S. M. D. L. Root-knot and lesion nematodes in coffee seedlings produced in the state of Minas Gerais, Brazil. [S. l.], v. 13, n. 2, p. 178–186, 2018.

TOH, C. M.; IZZUDDIN, M. A.; EWE, H. T.; IDRIS, A. S. Analysis of Oil Palms with Basal Stem Rot Disease with L Band SAR Data. *Em: IGARSS 2019 - 2019 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM 2019*, Yokohama, Japan. **Anais** [...]. Yokohama, Japan: IEEE, 2019. p. 4900–4903. DOI: 10.1109/IGARSS.2019.8899220. Disponível em: <https://ieeexplore.ieee.org/document/8899220/>. Acesso em: 24 ago. 2020.

TREVETT, J. W. **Imaging Radar for Resources Surveys**. [s.l.: s.n.]. Disponível em: <http://link.springer.com/openurl?genre=book&isbn=978-94-010-8314-0>. Acesso em: 17 ago. 2020.

TYAGI, Amit Kumar; ABRAHAM, Ajith (ORG.). **Recurrent Neural Networks: concepts and applications**. First edition ed. Boca Raton: CRC Press, 2023.

ULABY, Fawwaz T.; LONG, David G. **Microwave radar and radiometric remote sensing**. Ann Arbor: The University of Michigan Press, 2014.

ULABY, Fawwaz Tayssir; MOORE, Richard K.; FUNG, Adrian K.; ULABY, Fawwaz Tayssir. **Microwave remote sensing, fundamentals and radiometry**. Norwood, Mass: ARTECH House, 1981.

UR RAHMAN, Hidayat; JABBAR CH, Nadeem; MANZOOR, SanaUllah; NAJEEB, Fahad; SIDDIQUE, Muhammad Yasir; KHAN, Razaqat Alam. A comparative analysis of machine learning approaches for plant disease identification. [S. l.], 2017.

URBAZAEV, Mikhail; THIEL, Christian; CREMER, Felix; DUBAYAH, Ralph; MIGLIAVACCA, Mirco; REICHSTEIN, Markus; SCHMULLIUS, Christiane. Estimation of forest aboveground biomass and uncertainties by integration of field measurements, airborne LiDAR, and SAR and optical satellite data in Mexico. **Carbon Balance and Management**, [S. l.], v. 13, n. 1, p. 5, 2018. DOI: 10.1186/s13021-018-0093-5.

USTIN, Susan L. (ORG.). **Remote sensing for natural resource management and environmental monitoring**. Hoboken, NJ: John Wiley & Sons, 2004.

UTRILLA-CATALAN, Rebeca; RODRÍGUEZ-RIVERO, Rocío; NARVAEZ, Viviana; DÍAZ-BARCOS, Virginia; BLANCO, Maria; GALEANO, Javier. Growing Inequality in the Coffee Global Value Chain: A Complex Network Assessment. **Sustainability**, [S. l.], v. 14, n. 2, p. 672, 2022. DOI: 10.3390/su14020672.

VELÁSQUEZ, David; SÁNCHEZ, Alejandro; SARMIENTO, Sebastian; TORO, Mauricio; MAIZA, Mikel; SIERRA, Basilio. A Method for Detecting Coffee Leaf Rust through Wireless Sensor Networks, Remote Sensing, and Deep Learning: Case Study of the Caturra Variety in Colombia. **Applied Sciences**, [S. l.], v. 10, n. 2, p. 697, 2020. a. DOI: 10.3390/app10020697. Disponível em: <https://www.mdpi.com/2076-3417/10/2/697>. Acesso em: 14 jul. 2020.

---

VELÁSQUEZ, David; SÁNCHEZ, Alejandro; SARMIENTO, Sebastian; TORO, Mauricio; MAIZA, Mikel; SIERRA, Basilio. A Method for Detecting Coffee Leaf Rust through Wireless Sensor Networks, Remote Sensing, and Deep Learning: Case Study of the Caturra Variety in Colombia. **Applied Sciences**, [S. l.], v. 10, n. 2, p. 697, 2020. b. DOI: 10.3390/app10020697.

VELOSO, Amanda; MERMOZ, Stéphane; BOUVET, Alexandre; LE TOAN, Thuy; PLANELLS, Milena; DEJOUX, Jean-François; CESCHIA, Eric. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. **Remote Sensing of Environment**, [S. l.], v. 199, p. 415–426, 2017. DOI: 10.1016/j.rse.2017.07.015.

VILELA, Emerson Ferreira; FERREIRA, Williams Pinto Marques; CASTRO, Gabriel Dumbá Monteiro De; FARIA, Ana Luísa Ribeiro De; LEITE, Daniel Henrique; LIMA, Igor Arantes; MATOS, Christiano de Sousa Machado De; SILVA, Rogério Antonio; VENZON, Madelaine. New Spectral Index and Machine Learning Models for Detecting Coffee Leaf Miner Infestation Using Sentinel-2 Multispectral Imagery. **Agriculture**, [S. l.], v. 13, n. 2, p. 388, 2023. DOI: 10.3390/agriculture13020388.

WANG, Kai. A study of a cubic spline interpolation. [S. l.], 2013.

WANG, Xue *et al.*, Evaluating the Effectiveness of Machine Learning and Deep Learning Models Combined Time-Series Satellite Data for Multiple Crop Types Classification over a Large-Scale Region. **Remote Sensing**, [S. l.], v. 14, n. 10, p. 2341, 2022. DOI: 10.3390/rs14102341.

XIAO, Yingxin; DONG, Yingying; HUANG, Wenjiang; LIU, Linyi. Regional prediction of Fusarium head blight occurrence in wheat with remote sensing based Susceptible-Exposed-Infect-*F-Scores*-Removed model. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 114, p. 103043, 2022. DOI: 10.1016/j.jag.2022.103043.

XUE, Jinru; SU, Baofeng. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. **Journal of Sensors**, [S. l.], v. 2017, p. 1–17, 2017. DOI: 10.1155/2017/1353691. Disponível em: <https://www.hindawi.com/journals/js/2017/1353691/>. Acesso em: 31 ago. 2020.

YAMAGUCHI, Yoshio. **Polarimetric SAR imaging: theory and applications**. First edition ed. Boca Raton: CRC Press, 2020.

YAMAMOTO, Shuhei; NOMOTO, Shuhei; HASHIMOTO, Naoyuki; MAKI, Masayasu; HONGO, Chiharu; SHIRAIWA, Tatsuhiko; HOMMA, Koki. Monitoring spatial and time-series variations in red crown rot damage of soybean in farmer fields based on UAV remote sensing. **Plant Production Science**, [S. l.], v. 26, n. 1, p. 36–47, 2023. DOI: 10.1080/1343943X.2023.2178469.

YANG, Shuting; GU, Lingjia; LI, Xiaofeng; JIANG, Tao; REN, Ruizhi. Crop Classification Method Based on Optimal Feature Selection and Hybrid CNN-RF Networks for Multi-Temporal Remote Sensing Imagery. **Remote Sensing**, [S. l.], v. 12, n. 19, p. 3119, 2020. DOI: 10.3390/rs12193119.

---

YIN, Junru; QI, Changsheng; CHEN, Qiqiang; QU, Jiantao. Spatial-Spectral Network for Hyperspectral Image Classification: A 3-D CNN and Bi-LSTM Framework. **Remote Sensing**, [S. l.], v. 13, n. 12, p. 2353, 2021. DOI: 10.3390/rs13122353.

ZHANG, Jingcheng; HUANG, Yanbo; PU, Ruiliang; GONZALEZ-MORENO, Pablo; YUAN, Lin; WU, Kaihua; HUANG, Wenjiang. Monitoring plant diseases and pests through remote sensing technology: A review. **Computers and Electronics in Agriculture**, [S. l.], v. 165, p. 104943, 2019. DOI: 10.1016/j.compag.2019.104943. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S016816991930290X>. Acesso em: 17 ago. 2020.

ZHANG, Minghua; QIN, Zhihao; LIU, Xue; USTIN, Susan L. Detection of stress in tomatoes induced by late blight disease in California, USA, using hyperspectral remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 4, n. 4, p. 295–310, 2003. DOI: 10.1016/S0303-2434(03)00008-4. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243403000084>. Acesso em: 14 jul. 2020.

ZHAO, Hongwei; CHEN, Zhongxin; JIANG, Hao; JING, Wenlong; SUN, Liang; FENG, Min. Evaluation of Three Deep Learning Models for Early Crop Classification Using Sentinel-1A Imagery Time Series—A Case Study in Zhanjiang, China. **Remote Sensing**, [S. l.], v. 11, n. 22, p. 2673, 2019. DOI: 10.3390/rs11222673.

ZHAO, Jinling; XU, Chao; XU, Jianpeng; HUANG, Linsheng; ZHANG, Dongyan; LIANG, Dong. Forecasting the wheat powdery mildew (*Blumeria graminis* f. Sp. tritici) using a remote sensing-based decision-tree classification at a provincial scale. **Australasian Plant Pathology**, [S. l.], v. 47, n. 1, p. 53–61, 2018. DOI: 10.1007/s13313-017-0527-7. Disponível em: <http://link.springer.com/10.1007/s13313-017-0527-7>. Acesso em: 24 ago. 2020.

ZHAO, Wenzhi; QU, Yang; CHEN, Jiage; YUAN, Zhanliang. Deeply synergistic optical and SAR time series for crop dynamic monitoring. **Remote Sensing of Environment**, [S. l.], v. 247, p. 111952, 2020. DOI: 10.1016/j.rse.2020.111952.

ŽIBRAT, Uroš; GERIČ STARE, Barbara; KNAPIČ, Matej; SUSIČ, Nik; LAPAJNE, Janez; ŠIRCA, Saša. Detection of Root-Knot Nematode *Meloidogyne luci* Infestation of Potato Tubers Using Hyperspectral Remote Sensing and Real-Time PCR Molecular Methods. **Remote Sensing**, [S. l.], v. 13, n. 10, p. 1996, 2021. DOI: 10.3390/rs13101996.

ZISKA, Lewis; BRADLEY, Bethany; WALLACE, Rebekah; BARGERON, Charles; LAFOREST, Joseph; CHOUDHURY, Robin; GARRETT, Karen; VEGA, Fernando. Climate Change, Carbon Dioxide, and Pest Biology, Managing the Future: Coffee as a Case Study. **Agronomy**, [S. l.], v. 8, n. 8, p. 152, 2018. DOI: 10.3390/agronomy8080152.

## APÊNDICE A – RESULTADO DA DIFERENÇA ENTRE VALORES MÉDIOS E DE VARIÂNCIA DOS ATRIBUTOS ÓPTICOS E SAR

**Tabela 1** - Diferença entre valores médios dos atributos ópticos por fase fenológica

|      | Fases | B4     | B5     | B6     | B7     | B8     | B8A    | B11    | B12    | NDVI   |
|------|-------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 2017 | FG    | 0.0183 | 0.0151 | 0.0224 | 0.041  | 0.0365 | 0.0359 | 0.0542 | 0.0408 | 0.0958 |
|      | MF    | 0.0122 | 0.0098 | 0.0232 | 0.04   | 0.0379 | 0.038  | 0.0418 | 0.0319 | 0.0886 |
|      | AP    | 0.0058 | 0.0025 | 0.0387 | 0.0625 | 0.0621 | 0.0632 | 0.0089 | 0.0097 | 0.067  |
|      | VG    | 0.004  | 0.0021 | 0.0252 | 0.0411 | 0.0403 | 0.0408 | 0.0104 | 0.0099 | 0.0331 |
| 2018 | FG    | 0.0156 | 0.0197 | 0.0221 | 0.0217 | 0.0214 | 0.0242 | 0.0361 | 0.0261 | 0.0324 |
|      | MF    | 0.0107 | 0.0103 | 0.0224 | 0.0315 | 0.0303 | 0.0316 | 0.0362 | 0.028  | 0.0297 |
|      | AP    | 0.0102 | 0.002  | 0.0173 | 0.0231 | 0.0243 | 0.0273 | 0.0223 | 0.0237 | 0.0636 |
|      | VG    | 0.0074 | 0.0164 | 0.0584 | 0.079  | 0.08   | 0.0824 | 0.0121 | 0.003  | 0.0333 |
| 2019 | FG    | 0.0145 | 0.0226 | 0.0549 | 0.0673 | 0.0684 | 0.0675 | 0.0017 | 0.0025 | 0.0314 |
|      | MF    | 0.026  | 0.0173 | 0.0209 | 0.0335 | 0.0359 | 0.0383 | 0.0494 | 0.0514 | 0.1544 |
|      | AP    | 0.0186 | 0.0091 | 0.0511 | 0.0779 | 0.0795 | 0.0828 | 0.0295 | 0.0353 | 0.1547 |
|      | VG    | 0.0092 | 0.0019 | 0.0451 | 0.0652 | 0.0646 | 0.0671 | 0.0093 | 0.0147 | 0.0867 |
| 2020 | FG    | 0.0182 | 0.013  | 0.0188 | 0.0308 | 0.0317 | 0.0329 | 0.0354 | 0.0342 | 0.1077 |
|      | MF    | 0.0298 | 0.0276 | 0.0074 | 0.0024 | 0.0009 | 0.0019 | 0.0564 | 0.0533 | 0.1119 |
|      | AP    | 0.024  | 0.0164 | 0.0024 | 0.0031 | 0.0058 | 0.0058 | 0.0412 | 0.044  | 0.1074 |
|      | VG    | 0.0169 | 0.0089 | 0.0348 | 0.0562 | 0.0571 | 0.0605 | 0.0264 | 0.0302 | 0.1171 |
| 2021 | FG    | 0.0158 | 0.0148 | 0.0044 | 0.0173 | 0.0183 | 0.0186 | 0.0293 | 0.0244 | 0.0733 |
|      | MF    | 0.0283 | 0.0242 | 0.0058 | 0.0189 | 0.0216 | 0.0223 | 0.0544 | 0.0485 | 0.1521 |
|      | AP    | 0.0332 | 0.0317 | 0.0121 | 0.0366 | 0.0371 | 0.0362 | 0.0759 | 0.0631 | 0.1905 |
|      | VG    | 0.0286 | 0.0327 | 0.0133 | 0.002  | 0.0007 | 0.0023 | 0.0744 | 0.0535 | 0.1331 |

**Tabela 2** - Diferença entre valores de variância média dos atributos ópticos por fase fenológica

|      | Fases | B4     | B5     | B6     | B7     | B8     | B8A    | B11    | B12     | NDVI   |
|------|-------|--------|--------|--------|--------|--------|--------|--------|---------|--------|
| 2017 | FG    | 0.0002 | 0.0002 | 0.0006 | 0.0013 | 0.0013 | 0.0015 | 0.0004 | 0.0002  | 0.0008 |
|      | MF    | 0      | 0      | 0.0004 | 0.0008 | 0.0008 | 0.0009 | 0.0004 | 0.0003  | 0.0019 |
|      | AP    | 0.0001 | 0.0001 | 0.0005 | 0.0008 | 0.0009 | 0.0009 | 0.0006 | 0.0003  | 0.0015 |
|      | VG    | 0.0001 | 0.0002 | 0.0008 | 0.0014 | 0.0015 | 0.0016 | 0.0009 | 0.0004  | 0.002  |
| 2018 | FG    | 0.0006 | 0.0002 | 0.0024 | 0.0044 | 0.0044 | 0.005  | 0.0014 | 0.0001  | 0.0003 |
|      | MF    | 0.0005 | 0.0005 | 0.0017 | 0.0025 | 0.0026 | 0.0027 | 0.0018 | 0.0008  | 0.006  |
|      | AP    | 0.0003 | 0.0003 | 0.0007 | 0.001  | 0.0011 | 0.0011 | 0.0009 | 0.0004  | 0.0033 |
|      | VG    | 0.0022 | 0.0022 | 0.0012 | 0.001  | 0.0011 | 0.0009 | 0.0013 | 0.0014  | 0.0033 |
| 2019 | FG    | 0.0051 | 0.0052 | 0.0026 | 0.0019 | 0.0022 | 0.0017 | 0.003  | 0.0034  | 0.0082 |
|      | MF    | 0.0001 | 0.0001 | 0.0002 | 0.0004 | 0.0004 | 0.0004 | 0.0001 | 0.00001 | 0.0001 |
|      | AP    | 0.0001 | 0.0001 | 0.0001 | 0.0003 | 0.0003 | 0.0003 | 0.0002 | 0.0001  | 0.0015 |
|      | VG    | 0.0001 | 0.0001 | 0.0003 | 0.0007 | 0.0007 | 0.0007 | 0.0001 | 0.00008 | 0.0006 |
| 2020 | FG    | 0.0007 | 0.0007 | 0.0008 | 0.0011 | 0.0011 | 0.0012 | 0.0008 | 0.0006  | 0.0021 |
|      | MF    | 0.0007 | 0.0009 | 0.0014 | 0.0019 | 0.002  | 0.0021 | 0.0027 | 0.0013  | 0.0037 |
|      | AP    | 0.0004 | 0.0006 | 0.0011 | 0.0016 | 0.0017 | 0.0018 | 0.0026 | 0.0011  | 0.0026 |
|      | VG    | 0      | 0      | 0.0001 | 0.0003 | 0.0003 | 0.0003 | 0.0002 | 0.00004 | 0.0001 |
| 2021 | FG    | 0.0003 | 0.0003 | 0.0002 | 0.0004 | 0.0007 | 0.0004 | 0.0001 | 0.0002  | 0.0024 |
|      | MF    | 0      | 0      | 0.0002 | 0.0003 | 0.0003 | 0.0004 | 0.0004 | 0.0002  | 0.0013 |
|      | AP    | 0.0007 | 0.0008 | 0.0013 | 0.0019 | 0.0021 | 0.0022 | 0.0012 | 0.0008  | 0.0022 |
|      | VG    | 0.0016 | 0.0018 | 0.0022 | 0.0032 | 0.0034 | 0.0036 | 0.0019 | 0.0016  | 0.008  |

**Tabela 3** - Diferença entre valores médios dos atributos SAR por fase fenológica

|      | Fases | $\sigma^0VV$ | $\sigma^0VH$ | sumVVVH | subVVVH | ratioVVVH | RVI    |
|------|-------|--------------|--------------|---------|---------|-----------|--------|
| 2017 | FG    | 0.8365       | 0.028        | 0.8085  | 0.8645  | 0.0587    | 0.1218 |
|      | MF    | 0.9292       | 0.0804       | 1.0096  | 0.8487  | 0.0577    | 0.1223 |
|      | AP    | 1.1993       | 0.6921       | 1.8914  | 0.5071  | 0.0508    | 0.0637 |
|      | VG    | 1.2325       | 0.7806       | 2.0132  | 0.4518  | 0.0533    | 0.0585 |
| 2018 | FG    | 1.0433       | 0.929        | 1.9724  | 0.1143  | 0.0327    | 0.0111 |
|      | MF    | 1.2075       | 1.2835       | 2.491   | 0.076   | 0.026     | 0.0193 |
|      | AP    | 1.5533       | 1.2209       | 2.7743  | 0.3323  | 0.0544    | 0.0403 |
|      | VG    | 1.525        | 0.8084       | 2.3334  | 0.7165  | 0.0731    | 0.097  |
| 2019 | FG    | 1.8673       | 1.316        | 3.1834  | 0.5512  | 0.0695    | 0.0637 |
|      | MF    | 2.1238       | 1.5748       | 3.6987  | 0.5489  | 0.0713    | 0.0152 |
|      | AP    | 2.0152       | 1.4238       | 3.4391  | 0.5913  | 0.0743    | 0.0495 |
|      | VG    | 1.8743       | 1.4295       | 3.3038  | 0.4448  | 0.0686    | 0.0623 |
| 2020 | FG    | 1.9024       | 1.6808       | 3.5832  | 0.2215  | 0.0572    | 0.0247 |
|      | MF    | 2.6679       | 2.6164       | 5.2844  | 0.0515  | 0.0676    | 0.001  |
|      | AP    | 2.7333       | 2.1683       | 4.9016  | 0.565   | 0.0932    | 0.0714 |
|      | VG    | 2.1947       | 1.2593       | 3.4541  | 0.9354  | 0.0981    | 0.1241 |
| 2021 | FG    | 1.9535       | 1.5671       | 3.5206  | 0.3864  | 0.0642    | 0.0515 |
|      | MF    | 2.6772       | 2.2815       | 4.9587  | 0.3956  | 0.0736    | 0.0482 |
|      | AP    | 2.7703       | 1.8113       | 4.5816  | 0.9589  | 0.1008    | 0.1253 |
|      | VG    | 2.1241       | 1.3891       | 3.5132  | 0.735   | 0.0828    | 0.0997 |

**Tabela 4** - Diferença entre valores de variância média dos atributos ópticos por fase fenológica

|      | Fases | $\sigma^0VV$ | $\sigma^0VH$ | sumVVVH | subVVVH | ratVVVH | RVI    |
|------|-------|--------------|--------------|---------|---------|---------|--------|
| 2017 | FG    | 0.68743      | 0.9381       | 3.0527  | 0.5123  | 0.0018  | 0.0041 |
|      | MF    | 0.50603      | 0.2437       | 1.0733  | 0.1984  | 0.0003  | 0.0071 |
|      | AP    | 0.40964      | 0.2182       | 0.8985  | 0.4262  | 0.002   | 0.0035 |
|      | VG    | 0.26928      | 0.1557       | 0.4831  | 0.3571  | 0.0019  | 0.0016 |
| 2018 | FG    | 0.40389      | 0.0282       | 0.4163  | 0.367   | 0.0023  | 0.0094 |
|      | MF    | 0.21418      | 0.2221       | 0.591   | 0.448   | 0.0028  | 0.0112 |
|      | AP    | 0.16983      | 0.0996       | 0.326   | 0.2815  | 0.0017  | 0.0022 |
|      | VG    | 0.27987      | 0.2358       | 0.5303  | 0.2129  | 0.0013  | 0.0012 |
| 2019 | FG    | 0.21845      | 0.4346       | 1.078   | 0.501   | 0.0026  | 0.0072 |
|      | MF    | 0.22553      | 0.2488       | 0.6049  | 0.228   | 0.0011  | 0.0037 |
|      | AP    | 0.2871       | 0.0746       | 0.517   | 0.3437  | 0.002   | 0.0027 |
|      | VG    | 0.4486       | 0.3038       | 1.1245  | 0.2064  | 0.0019  | 0.0007 |
| 2020 | FG    | 0.28098      | 0.2889       | 0.5526  | 0.3803  | 0.0023  | 0.0051 |
|      | MF    | 0.17966      | 0.0191       | 0.053   | 0.5872  | 0.0038  | 0.0124 |
|      | AP    | 0.45664      | 0.1088       | 0.9613  | 0.2681  | 0.0021  | 0.0004 |
|      | VG    | 0.36332      | 0.6006       | 1.6261  | 0.1696  | 0.0021  | 0.0061 |
| 2021 | FG    | 0.58905      | 1.0136       | 2.6228  | 0.3017  | 0.002   | 0.0061 |
|      | MF    | 0.51025      | 0.34         | 1.4626  | 0.5824  | 0.0024  | 0.008  |
|      | AP    | 0.53142      | 0.432        | 1.5698  | 0.238   | 0.0022  | 0.0032 |
|      | VG    | 0.687427     | 0.3561       | 1.3524  | 0.3571  | 0.0022  | 0.0008 |

## APÊNDICE B – RESULTADOS OBTIDOS PARA O TREINAMENTO DA REDE BILSTM A PARTIR DO CENÁRIO EXPERIMENTAL 1

**Tabela 1** – Cenário 1: Resultados do treinamento considerando atributos ópticos e SAR, separadamente: (a) 12 meses, (b) 24 meses, (c) 36 meses, (d) 48 meses e (e) 60 meses.

|           |          |           | Precision |           | Recall  |           | F1    |           |      |      |      |
|-----------|----------|-----------|-----------|-----------|---------|-----------|-------|-----------|------|------|------|
|           |          |           | Sadio     | Infestado | Sadio   | Infestado | Sadio | Infestado |      |      |      |
|           |          |           |           |           |         |           |       |           |      |      |      |
| (a)       | 12 meses | Óptico    | VIS       | 0.95      | 1       | 1.00      | 0.85  | 0.97      | 0.92 |      |      |
|           |          |           | VIS+NIR   | 0.98      | 0.96    | 0.99      | 0.95  | 0.98      | 0.95 |      |      |
|           |          |           | VIS+RED1  | 0.96      | 0.98    | 0.99      | 0.89  | 0.98      | 0.93 |      |      |
|           |          |           | VIS+RED2  | 0.97      | 0.99    | 1.00      | 0.90  | 0.98      | 0.95 |      |      |
|           |          |           | VIS+RED3  | 0.98      | 0.96    | 0.99      | 0.95  | 0.99      | 0.95 |      |      |
|           |          |           | VIS+RED4  | 0.96      | 0.98    | 0.99      | 0.89  | 0.98      | 0.93 |      |      |
|           |          |           | VIS+SWIR1 | 0.94      | 1       | 1.00      | 0.80  | 0.97      | 0.89 |      |      |
|           |          |           | VIS+SWIR2 | 0.97      | 0.98    | 0.99      | 0.89  | 0.98      | 0.93 |      |      |
|           |          |           | VIS+NDVI  | 0.94      | 0.96    | 0.99      | 0.80  | 0.96      | 0.87 |      |      |
|           |          | SAR       | VV        | 0.81      | 0.83    | 0.98      | 0.3   | 0.89      | 0.44 |      |      |
|           |          |           | VH        | 0.8       | 0.87    | 0.99      | 0.27  | 0.89      | 0.41 |      |      |
|           |          |           | sumVVVH   | 0.82      | 0.86    | 0.98      | 0.34  | 0.89      | 0.48 |      |      |
|           |          | (b)       | 24 meses  | Óptico    | VIS     | 1.00      | 0.9   | 0.96      | 1.00 | 0.98 | 0.94 |
|           |          |           |           |           | VIS+NIR | 1.00      | 0.9   | 0.96      | 1.00 | 0.98 | 0.95 |
| VIS+RED1  | 0.98     |           |           |           | 0.95    | 0.98      | 0.95  | 0.98      | 0.95 |      |      |
| VIS+RED2  | 1.00     |           |           |           | 0.89    | 0.96      | 1.00  | 0.98      | 0.94 |      |      |
| VIS+RED3  | 1.00     |           |           |           | 0.9     | 0.96      | 1.00  | 0.98      | 0.95 |      |      |
| VIS+RED4  | 1.00     |           |           |           | 0.98    | 0.99      | 1.00  | 1.00      | 0.99 |      |      |
| VIS+SWIR1 | 1.00     |           |           |           | 0.92    | 0.97      | 1.00  | 0.99      | 0.96 |      |      |
| VIS+SWIR2 | 1.00     |           |           |           | 0.89    | 0.96      | 1.00  | 0.98      | 0.94 |      |      |
| VIS+NDVI  | 0.98     |           |           |           | 0.91    | 0.97      | 0.94  | 0.97      | 0.92 |      |      |
| SAR       | VV       |           |           | 0.86      | 0.84    | 0.97      | 0.52  | 0.91      | 0.64 |      |      |
|           | VH       |           |           | 0.85      | 0.96    | 0.99      | 0.47  | 0.92      | 0.63 |      |      |
|           | sumVVVH  |           |           | 0.85      | 0.97    | 0.99      | 0.48  | 0.92      | 0.64 |      |      |
| (c)       | 36 meses |           |           | Óptico    | VIS     | 0.99      | 0.99  | 1.00      | 0.98 | 0.99 | 0.98 |
|           |          |           |           |           | VIS+NIR | 1.00      | 0.94  | 0.98      | 1.00 | 0.99 | 0.97 |
|           |          | VIS+RED1  | 1.00      |           | 0.91    | 0.97      | 1.00  | 0.98      | 0.95 |      |      |
|           |          | VIS+RED2  | 1.00      |           | 0.93    | 0.98      | 1.00  | 0.99      | 0.97 |      |      |
|           |          | VIS+RED3  | 0.99      |           | 0.99    | 1.00      | 0.98  | 1.00      | 0.99 |      |      |
|           |          | VIS+RED4  | 1.00      |           | 0.95    | 0.98      | 0.99  | 0.99      | 0.97 |      |      |
|           |          | VIS+SWIR1 | 1.00      |           | 0.96    | 0.99      | 1.00  | 0.99      | 0.98 |      |      |
|           |          | VIS+SWIR2 | 1.00      |           | 0.99    | 1.00      | 1.00  | 1.00      | 0.99 |      |      |
|           |          | VIS+NDVI  | 0.98      |           | 0.99    | 1.00      | 0.95  | 0.99      | 0.97 |      |      |
|           |          | SAR       | VV        | 0.86      | 0.94    | 0.99      | 0.49  | 0.92      | 0.65 |      |      |
|           |          |           | VH        | 0.88      | 0.92    | 0.98      | 0.60  | 0.93      | 0.73 |      |      |
|           |          |           | sumVVVH   | 0.88      | 0.97    | 0.99      | 0.6   | 0.93      | 0.74 |      |      |
|           |          | (d)       | 48 meses  | Óptico    | VIS     | 1.00      | 0.98  | 0.99      | 1.00 | 1.00 | 0.99 |
|           |          |           |           |           | VIS+NIR | 0.99      | 0.97  | 0.99      | 0.96 | 0.99 | 0.97 |
| VIS+RED1  | 1.00     |           |           |           | 0.96    | 0.99      | 1.00  | 0.99      | 0.98 |      |      |
| VIS+RED2  | 1.00     |           |           |           | 0.98    | 0.99      | 0.99  | 1.00      | 0.99 |      |      |
| VIS+RED3  | 1.00     |           |           |           | 0.98    | 0.99      | 1.00  | 1.00      | 0.99 |      |      |
| VIS+RED4  | 1.00     |           |           |           | 0.94    | 0.98      | 1.00  | 0.99      | 0.97 |      |      |
| VIS+SWIR1 | 1.00     |           |           |           | 0.99    | 1.00      | 1.00  | 1.00      | 0.99 |      |      |
| VIS+SWIR2 | 1.00     |           |           |           | 0.99    | 1.00      | 1.00  | 1.00      | 0.99 |      |      |
| VIS+NDVI  | 0.99     |           |           |           | 0.98    | 0.99      | 0.96  | 0.99      | 0.97 |      |      |
| SAR       | VV       |           |           | 0.94      | 0.78    | 0.92      | 0.82  | 0.93      | 0.8  |      |      |
|           | VH       |           |           | 0.94      | 0.83    | 0.94      | 0.83  | 0.94      | 0.83 |      |      |
|           | sumVVVH  |           |           | 0.88      | 0.97    | 0.99      | 0.61  | 0.94      | 0.75 |      |      |
| (e)       | 60 meses |           |           | Óptico    | VIS     | 0.98      | 1     | 1.00      | 0.95 | 0.99 | 0.97 |
|           |          |           |           |           | VIS+NIR | 1.00      | 0.98  | 0.99      | 1.00 | 1.00 | 0.99 |
|           |          | VIS+RED1  | 1.00      |           | 0.96    | 0.99      | 1.00  | 0.99      | 0.98 |      |      |

|  |          |           |      |      |      |      |      |      |
|--|----------|-----------|------|------|------|------|------|------|
|  |          | VIS+RED2  | 0.99 | 0.98 | 0.99 | 0.97 | 0.99 | 0.98 |
|  |          | VIS+RED3  | 1.00 | 0.94 | 0.98 | 1.00 | 0.99 | 0.97 |
|  |          | VIS+RED4  | 0.99 | 0.99 | 1.00 | 0.98 | 0.99 | 0.98 |
|  |          | VIS+SWIR1 | 1.00 | 0.96 | 0.99 | 1.00 | 0.99 | 0.98 |
|  |          | VIS+SWIR2 | 1.00 | 0.97 | 0.99 | 1.00 | 0.99 | 0.98 |
|  | VIS+NDVI | 0.95      | 1    | 1.00 | 0.84 | 0.97 | 0.91 |      |
|  | SAR      | VV        | 0.95 | 0.8  | 0.93 | 0.86 | 0.94 | 0.83 |
|  |          | VH        | 0.94 | 0.92 | 0.98 | 0.80 | 0.96 | 0.85 |
|  |          | sumVVVH   | 0.92 | 0.94 | 0.98 | 0.74 | 0.95 | 0.83 |

**Tabela 2** – Cenário 1: Resultados do treinamento considerando a combinação de atributos ópticos e a polarização  $\sigma^0$ VV, separadamente: (a) 12 meses, (b) 24 meses, (c) 36 meses, (d) 48 meses e (e) 60 meses.

|     |          | Precision    |           | Recall |           | F1    |           |      |
|-----|----------|--------------|-----------|--------|-----------|-------|-----------|------|
|     |          | Sadio        | Infestado | Sadio  | Infestado | Sadio | Infestado |      |
|     |          |              |           |        |           |       |           |      |
| (a) | 12 meses | VIS+VV       | 0.94      | 0.99   | 1.00      | 0.80  | 0.97      | 0.88 |
|     |          | VIS+NIR+VV   | 0.94      | 1      | 1.00      | 0.79  | 0.97      | 0.88 |
|     |          | VIS+RED1+VV  | 0.97      | 0.97   | 0.99      | 0.89  | 0.98      | 0.93 |
|     |          | VIS+RED2+VV  | 0.94      | 0.99   | 1.00      | 0.80  | 0.97      | 0.88 |
|     |          | VIS+RED3+VV  | 0.93      | 1      | 1.00      | 0.76  | 0.96      | 0.87 |
|     |          | VIS+RED4+VV  | 0.99      | 0.81   | 0.92      | 0.96  | 0.95      | 0.88 |
|     |          | VIS+SWIR1+VV | 0.94      | 0.99   | 1.00      | 0.80  | 0.97      | 0.89 |
|     |          | VIS+SWIR2+VV | 0.94      | 0.99   | 1.00      | 0.80  | 0.97      | 0.89 |
|     |          | VIS+NDVI+VV  | 0.93      | 1      | 1.00      | 0.78  | 0.96      | 0.87 |
| (b) | 24 meses | VIS+VV       | 1.00      | 0.89   | 0.96      | 1.00  | 0.98      | 0.94 |
|     |          | VIS+NIR+VV   | 0.94      | 1      | 1.00      | 0.82  | 0.97      | 0.9  |
|     |          | VIS+RED1+VV  | 0.96      | 0.93   | 0.98      | 0.87  | 0.97      | 0.9  |
|     |          | VIS+RED2+VV  | 0.98      | 0.93   | 0.98      | 0.94  | 0.98      | 0.93 |
|     |          | VIS+RED3+VV  | 1.00      | 0.9    | 0.96      | 0.99  | 0.98      | 0.94 |
|     |          | VIS+RED4+VV  | 0.98      | 0.92   | 0.97      | 0.95  | 0.98      | 0.94 |
|     |          | VIS+SWIR1+VV | 1.00      | 0.91   | 0.97      | 1.00  | 0.98      | 0.96 |
|     |          | VIS+SWIR2+VV | 1.00      | 0.97   | 0.99      | 0.99  | 0.99      | 0.88 |
|     |          | VIS+NDVI+VV  | 1.00      | 0.91   | 0.97      | 1.00  | 0.98      | 0.95 |
| (c) | 36 meses | VIS+VV       | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+NIR+VV   | 1.00      | 0.99   | 1.00      | 0.99  | 1.00      | 0.99 |
|     |          | VIS+RED1+VV  | 1.00      | 0.99   | 1.00      | 0.99  | 1.00      | 0.99 |
|     |          | VIS+RED2+VV  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED3+VV  | 0.99      | 0.99   | 1.00      | 0.97  | 0.99      | 0.98 |
|     |          | VIS+RED4+VV  | 1.00      | 0.96   | 0.99      | 1.00  | 0.99      | 0.98 |
|     |          | VIS+SWIR1+VV | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+SWIR2+VV | 1.00      | 0.97   | 0.99      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+NDVI+VV  | 0.97      | 0.99   | 1.00      | 0.89  | 0.98      | 0.94 |
| (d) | 48 meses | VIS+VV       | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+NIR+VV   | 1.00      | 0.93   | 0.97      | 1.00  | 0.99      | 0.96 |
|     |          | VIS+RED1+VV  | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED2+VV  | 1.00      | 0.96   | 0.99      | 1.00  | 0.99      | 0.98 |
|     |          | VIS+RED3+VV  | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED4+VV  | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+SWIR1+VV | 1.00      | 0.96   | 0.99      | 1.00  | 0.99      | 0.98 |
|     |          | VIS+SWIR2+VV | 1.00      | 0.95   | 0.98      | 1.00  | 0.99      | 0.97 |
|     |          | VIS+NDVI+VV  | 0.99      | 0.99   | 1.00      | 0.98  | 1.00      | 0.99 |
| (e) | 60 meses | VIS+VV       | 1.00      | 0.98   | 0.99      | 0.99  | 1.00      | 0.99 |
|     |          | VIS+NIR+VV   | 0.96      | 0.99   | 1.00      | 0.88  | 0.98      | 0.93 |
|     |          | VIS+RED1+VV  | 0.98      | 0.98   | 0.99      | 0.93  | 0.99      | 0.95 |
|     |          | VIS+RED2+VV  | 1.00      | 0.91   | 0.97      | 1.00  | 0.98      | 0.95 |
|     |          | VIS+RED3+VV  | 1.00      | 0.94   | 0.98      | 1.00  | 0.99      | 0.97 |

|  |              |      |      |      |      |      |      |
|--|--------------|------|------|------|------|------|------|
|  | VIS+RED4+VV  | 1.00 | 0.91 | 0.97 | 1.00 | 0.98 | 0.95 |
|  | VIS+SWIR1+VV | 1.00 | 0.95 | 0.98 | 1.00 | 0.99 | 0.98 |
|  | VIS+SWIR2+VV | 0.99 | 0.98 | 0.99 | 0.98 | 0.99 | 0.98 |
|  | VIS+NDVI+VV  | 0.99 | 0.98 | 0.99 | 0.96 | 0.99 | 0.97 |

**Tabela 3** – Cenário 1: Resultados do treinamento considerando a combinação de atributos ópticos e a polarização  $\sigma^0$ VH, separadamente: (a) 12 meses, (b) 24 meses, (c) 36 meses, (d) 48 meses e (e) 60 meses.

|     |          | Precision    |           | Recall |           | F1    |           |      |
|-----|----------|--------------|-----------|--------|-----------|-------|-----------|------|
|     |          | Sadio        | Infestado | Sadio  | Infestado | Sadio | Infestado |      |
|     |          |              |           |        |           |       |           |      |
| (a) | 12 meses | VIS+VH       | 0.94      | 1      | 1.00      | 0.80  | 0.97      | 0.89 |
|     |          | VIS+NIR+VH   | 0.96      | 0.97   | 0.99      | 0.88  | 0.98      | 0.92 |
|     |          | VIS+RED1+VH  | 0.96      | 0.96   | 0.99      | 0.88  | 0.97      | 0.92 |
|     |          | VIS+RED2+VH  | 0.94      | 0.99   | 1.00      | 0.80  | 0.97      | 0.88 |
|     |          | VIS+RED3+VH  | 0.93      | 1      | 1.00      | 0.79  | 0.97      | 0.88 |
|     |          | VIS+RED4+VH  | 0.94      | 0.98   | 1.00      | 0.80  | 0.97      | 0.88 |
|     |          | VIS+SWIR1+VH | 0.96      | 0.98   | 0.99      | 0.88  | 0.98      | 0.92 |
|     |          | VIS+SWIR2+VH | 0.97      | 0.99   | 1.00      | 0.91  | 0.98      | 0.95 |
|     |          | VIS+NDVI+VH  | 0.94      | 1      | 1.00      | 0.80  | 0.97      | 0.89 |
| (b) | 24 meses | VIS+VH       | 1.00      | 0.86   | 0.95      | 1.00  | 0.97      | 0.92 |
|     |          | VIS+NIR+VH   | 1.00      | 0.91   | 0.97      | 1.00  | 0.98      | 0.95 |
|     |          | VIS+RED1+VH  | 0.99      | 0.95   | 0.98      | 0.98  | 0.99      | 0.97 |
|     |          | VIS+RED2+VH  | 1.00      | 0.9    | 0.96      | 1.00  | 0.98      | 0.94 |
|     |          | VIS+RED3+VH  | 1.00      | 0.75   | 0.89      | 1.00  | 0.94      | 0.86 |
|     |          | VIS+RED4+VH  | 1.00      | 0.93   | 0.97      | 0.99  | 0.99      | 0.96 |
|     |          | VIS+SWIR1+VH | 1.00      | 0.91   | 0.97      | 0.99  | 0.98      | 0.95 |
|     |          | VIS+SWIR2+VH | 0.99      | 0.89   | 0.96      | 0.98  | 0.98      | 0.93 |
|     |          | VIS+NDVI+VH  | 0.99      | 0.92   | 0.97      | 0.97  | 0.98      | 0.95 |
| (c) | 36 meses | VIS+VH       | 0.99      | 0.99   | 1.00      | 0.98  | 1.00      | 0.99 |
|     |          | VIS+NIR+VH   | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED1+VH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED2+VH  | 1.00      | 0.92   | 0.97      | 1.00  | 0.99      | 0.96 |
|     |          | VIS+RED3+VH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED4+VH  | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+SWIR1+VH | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+SWIR2+VH | 1.00      | 1      | 1.00      | 0.99  | 1.00      | 1    |
|     |          | VIS+NDVI+VH  | 0.98      | 0.99   | 1.00      | 0.95  | 0.99      | 0.97 |
| (d) | 48 meses | VIS+VH       | 0.98      | 0.99   | 1.00      | 0.95  | 0.99      | 0.97 |
|     |          | VIS+NIR+VH   | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED1+VH  | 0.99      | 1      | 1.00      | 0.97  | 1.00      | 0.99 |
|     |          | VIS+RED2+VH  | 1.00      | 0.99   | 1.00      | 0.99  | 1.00      | 0.99 |
|     |          | VIS+RED3+VH  | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED4+VH  | 0.99      | 0.99   | 1.00      | 0.98  | 0.99      | 0.98 |
|     |          | VIS+SWIR1+VH | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+SWIR2+VH | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+NDVI+VH  | 1.00      | 0.95   | 0.98      | 1.00  | 0.99      | 0.98 |
| (e) | 60 meses | VIS+VH       | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+NIR+VH   | 1.00      | 0.94   | 0.98      | 1.00  | 0.99      | 0.97 |
|     |          | VIS+RED1+VH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED2+VH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED3+VH  | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99 |
|     |          | VIS+RED4+VH  | 0.96      | 1      | 1.00      | 0.86  | 0.98      | 0.93 |
|     |          | VIS+SWIR1+VH | 0.97      | 1      | 1.00      | 0.91  | 0.98      | 0.95 |
|     |          | VIS+SWIR2+VH | 0.99      | 0.99   | 1.00      | 0.96  | 0.99      | 0.98 |
|     |          | VIS+NDVI+VH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99 |

**Tabela 4** – Cenário 1: Resultados do treinamento considerando a combinação de atributos ópticos e o atributo sumVVDH, separadamente: (a) 12 meses, (b) 24 meses, (c) 36 meses, (d) 48 meses e (e) 60 meses.

|     |          | Precision      |           | Recall |           | F1    |           | Sadio |      |
|-----|----------|----------------|-----------|--------|-----------|-------|-----------|-------|------|
|     |          | Sadio          | Infestado | Sadio  | Infestado | Sadio | Infestado |       |      |
|     |          |                |           |        |           |       |           |       |      |
| (a) | 12 meses | VIS+VVDH       | 0.94      | 0.99   | 1.00      | 0.80  | 0.97      | 0.88  | 0.93 |
|     |          | VIS+NIR+VVDH   | 0.96      | 0.98   | 0.99      | 0.86  | 0.97      | 0.92  | 0.95 |
|     |          | VIS+RED1+VVDH  | 0.95      | 0.99   | 1.00      | 0.84  | 0.97      | 0.91  | 0.95 |
|     |          | VIS+RED2+VVDH  | 0.94      | 1      | 1.00      | 0.80  | 0.97      | 0.89  | 0.94 |
|     |          | VIS+RED3+VVDH  | 0.93      | 1      | 1.00      | 0.79  | 0.97      | 0.88  | 0.93 |
|     |          | VIS+RED4+VVDH  | 0.97      | 0.97   | 0.99      | 0.92  | 0.98      | 0.94  | 0.96 |
|     |          | VIS+SWIR1+VVDH | 0.94      | 1      | 1.00      | 0.80  | 0.97      | 0.89  | 0.94 |
|     |          | VIS+SWIR2+VVDH | 0.94      | 0.98   | 0.99      | 0.80  | 0.96      | 0.88  | 0.93 |
|     |          | VIS+NDVI+VVDH  | 0.99      | 0.99   | 1.00      | 0.80  | 0.97      | 0.88  | 0.93 |
| (b) | 24 meses | VIS+VVDH       | 1.00      | 0.87   | 0.95      | 1.00  | 0.98      | 0.93  | 0.95 |
|     |          | VIS+NIR+VVDH   | 0.98      | 0.92   | 0.97      | 0.95  | 0.98      | 0.93  | 0.96 |
|     |          | VIS+RED1+VVDH  | 0.98      | 0.93   | 0.98      | 0.95  | 0.98      | 0.94  | 0.96 |
|     |          | VIS+RED2+VVDH  | 0.98      | 0.91   | 0.97      | 0.95  | 0.98      | 0.93  | 0.95 |
|     |          | VIS+RED3+VVDH  | 0.97      | 0.93   | 0.98      | 0.90  | 0.97      | 0.92  | 0.95 |
|     |          | VIS+RED4+VVDH  | 0.99      | 0.92   | 0.97      | 0.97  | 0.98      | 0.95  | 0.96 |
|     |          | VIS+SWIR1+VVDH | 1.00      | 0.95   | 0.98      | 1.00  | 0.99      | 0.97  | 0.98 |
|     |          | VIS+SWIR2+VVDH | 1.00      | 0.95   | 0.98      | 1.00  | 0.99      | 0.97  | 0.98 |
|     |          | VIS+NDVI+VVDH  | 0.98      | 0.92   | 0.97      | 0.94  | 0.98      | 0.93  | 0.95 |
| (c) | 36 meses | VIS+VVDH       | 1.00      | 0.94   | 0.98      | 1.00  | 0.99      | 0.97  | 0.98 |
|     |          | VIS+NIR+VVDH   | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+RED1+VVDH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+RED2+VVDH  | 1.00      | 0.99   | 1.00      | 0.99  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+RED3+VVDH  | 0.99      | 0.99   | 1.00      | 0.98  | 0.99      | 0.98  | 0.99 |
|     |          | VIS+RED4+VVDH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+SWIR1+VVDH | 1.00      | 0.95   | 0.98      | 1.00  | 0.99      | 0.97  | 0.98 |
|     |          | VIS+SWIR2+VVDH | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+NDVI+VVDH  | 1.00      | 0.97   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
| (d) | 48 meses | VIS+VVDH       | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+NIR+VVDH   | 1.00      | 0.99   | 1.00      | 0.99  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+RED1+VVDH  | 1.00      | 0.97   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+RED2+VVDH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+RED3+VVDH  | 1.00      | 0.95   | 0.98      | 1.00  | 0.99      | 0.98  | 0.98 |
|     |          | VIS+RED4+VVDH  | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+SWIR1+VVDH | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+SWIR2+VVDH | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+NDVI+VVDH  | 1.00      | 0.98   | 0.99      | 0.99  | 0.99      | 0.98  | 0.99 |
| (e) | 60 meses | VIS+VVDH       | 0.96      | 1      | 1.00      | 0.89  | 0.98      | 0.94  | 0.96 |
|     |          | VIS+NIR+VVDH   | 1.00      | 0.95   | 0.98      | 1.00  | 0.99      | 0.98  | 0.98 |
|     |          | VIS+RED1+VVDH  | 1.00      | 0.95   | 0.98      | 1.00  | 0.99      | 0.97  | 0.98 |
|     |          | VIS+RED2+VVDH  | 1.00      | 0.92   | 0.97      | 1.00  | 0.99      | 0.96  | 0.97 |
|     |          | VIS+RED3+VVDH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+RED4+VVDH  | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+SWIR1+VVDH | 1.00      | 0.98   | 0.99      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+SWIR2+VVDH | 1.00      | 0.99   | 1.00      | 1.00  | 1.00      | 0.99  | 0.99 |
|     |          | VIS+NDVI+VVDH  | 0.94      | 1      | 1.00      | 0.81  | 0.97      | 0.9   | 0.94 |

## APÊNDICE C – RESULTADOS OBTIDOS PARA O TREINAMENTO DA REDE BILSTM A PARTIR DO CENÁRIO EXPERIMENTAL 2

**Tabela 1** – Cenário 2: Resultados do treinamento considerando atributos ópticos e SAR, separadamente: (a) Formação de Grãos, (b) Maturação dos Frutos, (c) Autopoda, (d) Vegetativo

|           |                   |                      | Precision |           | Recall |           | F1    |           |      |
|-----------|-------------------|----------------------|-----------|-----------|--------|-----------|-------|-----------|------|
|           |                   |                      | Sadio     | Infestado | Sadio  | Infestado | Sadio | Infestado |      |
|           |                   |                      |           |           |        |           |       |           |      |
| (a)       | Formação de grãos | Óptico               | VIS       | 0.99      | 0.92   | 0.97      | 0.97  | 0.98      | 0.95 |
|           |                   |                      | VIS+NIR   | 0.98      | 1      | 1         | 0.93  | 0.99      | 0.96 |
|           |                   |                      | VIS+RED1  | 1         | 0.95   | 0.98      | 1     | 0.99      | 0.97 |
|           |                   |                      | VIS+RED2  | 1         | 0.92   | 0.97      | 0.99  | 0.98      | 0.95 |
|           |                   |                      | VIS+RED3  | 0.99      | 0.95   | 0.98      | 0.98  | 0.99      | 0.96 |
|           |                   |                      | VIS+RED4  | 0.98      | 0.93   | 0.98      | 0.93  | 0.98      | 0.93 |
|           |                   |                      | VIS+SWIR1 | 0.98      | 0.94   | 0.98      | 0.95  | 0.98      | 0.95 |
|           |                   |                      | VIS+SWIR2 | 1         | 0.94   | 0.98      | 0.99  | 0.99      | 0.96 |
|           |                   |                      | VIS+NDVI  | 0.98      | 0.99   | 1         | 0.94  | 0.99      | 0.96 |
|           |                   |                      | SAR       | VV        | 0.83   | 0.84      | 0.97  | 0.4       | 0.9  |
|           | VH                | 0.89                 |           | 0.72      | 0.92   | 0.64      | 0.9   | 0.68      |      |
|           | sumVVVH           | 0.85                 |           | 0.88      | 0.98   | 0.49      | 0.91  | 0.63      |      |
|           | (b)               | Maturação dos frutos | Óptico    | VIS       | 1      | 0.9       | 0.96  | 1         | 0.98 |
| VIS+NIR   |                   |                      |           | 1         | 0.93   | 0.98      | 1     | 0.99      | 0.97 |
| VIS+RED1  |                   |                      |           | 1         | 0.85   | 0.94      | 1     | 0.97      | 0.92 |
| VIS+RED2  |                   |                      |           | 1         | 0.89   | 0.96      | 1     | 0.98      | 0.94 |
| VIS+RED3  |                   |                      |           | 0.99      | 0.99   | 1         | 0.98  | 0.99      | 0.98 |
| VIS+RED4  |                   |                      |           | 1         | 0.86   | 0.95      | 1     | 0.97      | 0.92 |
| VIS+SWIR1 |                   |                      |           | 1         | 0.91   | 0.97      | 1     | 0.98      | 0.95 |
| VIS+SWIR2 |                   |                      |           | 1         | 0.93   | 0.98      | 1     | 0.99      | 0.96 |
| VIS+NDVI  |                   |                      |           | 1         | 0.88   | 0.95      | 1     | 0.98      | 0.94 |
| SAR       |                   |                      |           | VV        | 0.88   | 0.92      | 0.98  | 0.61      | 0.93 |
|           |                   | VH                   | 0.93      | 0.85      | 0.96   | 0.78      | 0.94  | 0.82      |      |
|           |                   | sumVVVH              | 0.92      | 0.97      | 0.99   | 0.74      | 0.96  | 0.84      |      |
| (c)       |                   | Autopoda             | Óptico    | VIS       | 0.95   | 0.93      | 0.98  | 0.85      | 0.96 |
|           | VIS+NIR           |                      |           | 0.91      | 1      | 1         | 0.69  | 0.95      | 0.82 |
|           | VIS+RED1          |                      |           | 0.93      | 1      | 1         | 0.76  | 0.96      | 0.86 |
|           | VIS+RED2          |                      |           | 0.91      | 1      | 1         | 0.72  | 0.96      | 0.84 |
|           | VIS+RED3          |                      |           | 0.89      | 1      | 1         | 0.64  | 0.94      | 0.78 |
|           | VIS+RED4          |                      |           | 0.9       | 1      | 1         | 0.67  | 0.95      | 0.81 |
|           | VIS+SWIR1         |                      |           | 0.93      | 0.98   | 0.99      | 0.79  | 0.96      | 0.87 |
|           | VIS+SWIR2         |                      |           | 0.93      | 0.98   | 0.99      | 0.78  | 0.96      | 0.87 |
|           | VIS+NDVI          |                      |           | 0.86      | 0.89   | 0.98      | 0.51  | 0.91      | 0.65 |
|           | SAR               |                      |           | VV        | 0.81   | 0.82      | 0.98  | 0.33      | 0.89 |
|           |                   | VH                   | 0.78      | 0.76      | 0.98   | 0.19      | 0.87  | 0.3       |      |
|           |                   | sumVVVH              | 0.81      | 0.87      | 0.98   | 0.23      | 0.89  | 0.45      |      |
|           | (d)               | Vegetativo           | Óptico    | VIS       | 0.96   | 0.95      | 0.98  | 0.86      | 0.97 |
| VIS+NIR   |                   |                      |           | 0.96      | 1      | 1         | 0.86  | 0.98      | 0.93 |
| VIS+RED1  |                   |                      |           | 0.94      | 1      | 1         | 0.79  | 0.97      | 0.88 |
| VIS+RED2  |                   |                      |           | 0.99      | 0.95   | 0.98      | 0.96  | 0.99      | 0.96 |
| VIS+RED3  |                   |                      |           | 0.99      | 0.95   | 0.98      | 0.96  | 0.98      | 0.95 |
| VIS+RED4  |                   |                      |           | 0.99      | 0.91   | 0.97      | 0.98  | 0.98      | 0.94 |
| VIS+SWIR1 |                   |                      |           | 0.99      | 0.92   | 0.97      | 0.98  | 0.98      | 0.95 |
| VIS+SWIR2 |                   |                      |           | 0.96      | 0.98   | 0.99      | 0.89  | 0.98      | 0.93 |
| VIS+NDVI  |                   |                      |           | 0.94      | 1      | 1         | 0.79  | 0.97      | 0.88 |
| SAR       |                   |                      |           | VV        | 0.84   | 0.77      | 0.95  | 0.47      | 0.89 |
|           |                   | VH                   | 0.83      | 0.69      | 0.94   | 0.4       | 0.88  | 0.51      |      |
|           |                   | sumVVVH              | 0.83      | 0.82      | 0.97   | 0.4       | 0.9   | 0.54      |      |

**Tabela 2** – Cenário 2: Resultados do treinamento considerando a combinação de atributos ópticos e a polarização  $\sigma^0$ VV, separadamente: (a) Formação de Grãos, (b) Maturação dos Frutos, (c) Autopoda, (d) Vegetativo

|     |                      | Precision     |           | Recall |           | F1    |           |      |
|-----|----------------------|---------------|-----------|--------|-----------|-------|-----------|------|
|     |                      | Sadio         | Infestado | Sadio  | Infestado | Sadio | Infestado |      |
|     |                      |               |           |        |           |       |           |      |
| (a) | Formação de grãos    | VIS+VV        | 0.99      | 0.96   | 0.99      | 0.98  | 0.99      | 0.97 |
|     |                      | VIS+NIR+ VV   | 1         | 0.94   | 0.98      | 1     | 0.99      | 0.97 |
|     |                      | VIS+RED1+ VV  | 1         | 0.93   | 0.98      | 0.99  | 0.99      | 0.96 |
|     |                      | VIS+RED2+ VV  | 1         | 0.91   | 0.97      | 1     | 0.98      | 0.95 |
|     |                      | VIS+RED3+ VV  | 0.98      | 0.91   | 0.97      | 0.95  | 0.98      | 0.93 |
|     |                      | VIS+RED4+ VV  | 1         | 0.98   | 0.99      | 0.99  | 0.99      | 0.98 |
|     |                      | VIS+SWIR1+ VV | 1         | 0.98   | 0.99      | 1     | 1         | 0.99 |
|     |                      | VIS+SWIR2+ VV | 1         | 0.9    | 0.96      | 1     | 0.98      | 0.95 |
|     |                      | VIS+NDVI+ VV  | 0.99      | 0.98   | 0.99      | 0.96  | 0.99      | 0.97 |
| (b) | Maturação dos frutos | VIS+VV        | 1         | 0.91   | 0.97      | 1     | 0.98      | 0.95 |
|     |                      | VIS+NIR+ VV   | 1         | 0.91   | 0.97      | 1     | 0.98      | 0.95 |
|     |                      | VIS+RED1+ VV  | 0.98      | 0.99   | 1         | 0.94  | 0.99      | 0.96 |
|     |                      | VIS+RED2+ VV  | 1         | 0.98   | 0.99      | 1     | 1         | 0.99 |
|     |                      | VIS+RED3+ VV  | 1         | 0.96   | 0.99      | 1     | 0.99      | 0.98 |
|     |                      | VIS+RED4+ VV  | 1         | 0.92   | 0.97      | 1     | 0.99      | 0.96 |
|     |                      | VIS+SWIR1+ VV | 0.97      | 0.99   | 1         | 0.9   | 0.98      | 0.94 |
|     |                      | VIS+SWIR2+ VV | 1         | 0.98   | 0.99      | 1     | 1         | 0.99 |
|     |                      | VIS+NDVI+ VV  | 0.97      | 0.99   | 1         | 0.9   | 0.98      | 0.94 |
| (c) | Autopoda             | VIS+VV        | 0.93      | 0.96   | 0.99      | 0.77  | 0.96      | 0.85 |
|     |                      | VIS+NIR+ VV   | 0.95      | 0.93   | 0.98      | 0.85  | 0.97      | 0.89 |
|     |                      | VIS+RED1+ VV  | 0.91      | 1      | 1         | 0.69  | 0.95      | 0.81 |
|     |                      | VIS+RED2+ VV  | 0.91      | 1      | 1         | 0.69  | 0.95      | 0.81 |
|     |                      | VIS+RED3+ VV  | 0.93      | 0.99   | 1         | 0.77  | 0.96      | 0.87 |
|     |                      | VIS+RED4+ VV  | 0.9       | 1      | 1         | 0.66  | 0.95      | 0.8  |
|     |                      | VIS+SWIR1+ VV | 0.93      | 1      | 1         | 0.77  | 0.96      | 0.87 |
|     |                      | VIS+SWIR2+ VV | 0.94      | 1      | 1         | 0.79  | 0.97      | 0.89 |
|     |                      | VIS+NDVI+ VV  | 0.91      | 0.99   | 1         | 0.69  | 0.95      | 0.81 |
| (d) | Vegetativo           | VIS+VV        | 0.99      | 0.94   | 0.98      | 0.96  | 0.98      | 0.95 |
|     |                      | VIS+NIR+ VV   | 1         | 0.94   | 0.98      | 0.99  | 0.99      | 0.96 |
|     |                      | VIS+RED1+ VV  | 1         | 0.99   | 0.97      | 0.99  | 0.98      | 0.95 |
|     |                      | VIS+RED2+ VV  | 1         | 0.9    | 0.96      | 0.99  | 0.98      | 0.94 |
|     |                      | VIS+RED3+ VV  | 0.99      | 0.93   | 0.98      | 0.98  | 0.98      | 0.96 |
|     |                      | VIS+RED4+ VV  | 0.98      | 0.94   | 0.98      | 0.95  | 0.98      | 0.94 |
|     |                      | VIS+SWIR1+ VV | 1         | 0.93   | 0.97      | 0.99  | 0.98      | 0.96 |
|     |                      | VIS+SWIR2+ VV | 1         | 0.91   | 0.97      | 0.99  | 0.98      | 0.95 |
|     |                      | VIS+NDVI+ VV  | 0.98      | 0.93   | 0.97      | 0.95  | 0.98      | 0.94 |

**Tabela 3** – Cenário 2: Resultados do treinamento considerando a combinação de atributos ópticos e a polarização  $\sigma^0$ VH, separadamente: (a) Formação de Grãos, (b) Maturação dos Frutos, (c) Autopoda, (d) Vegetativo

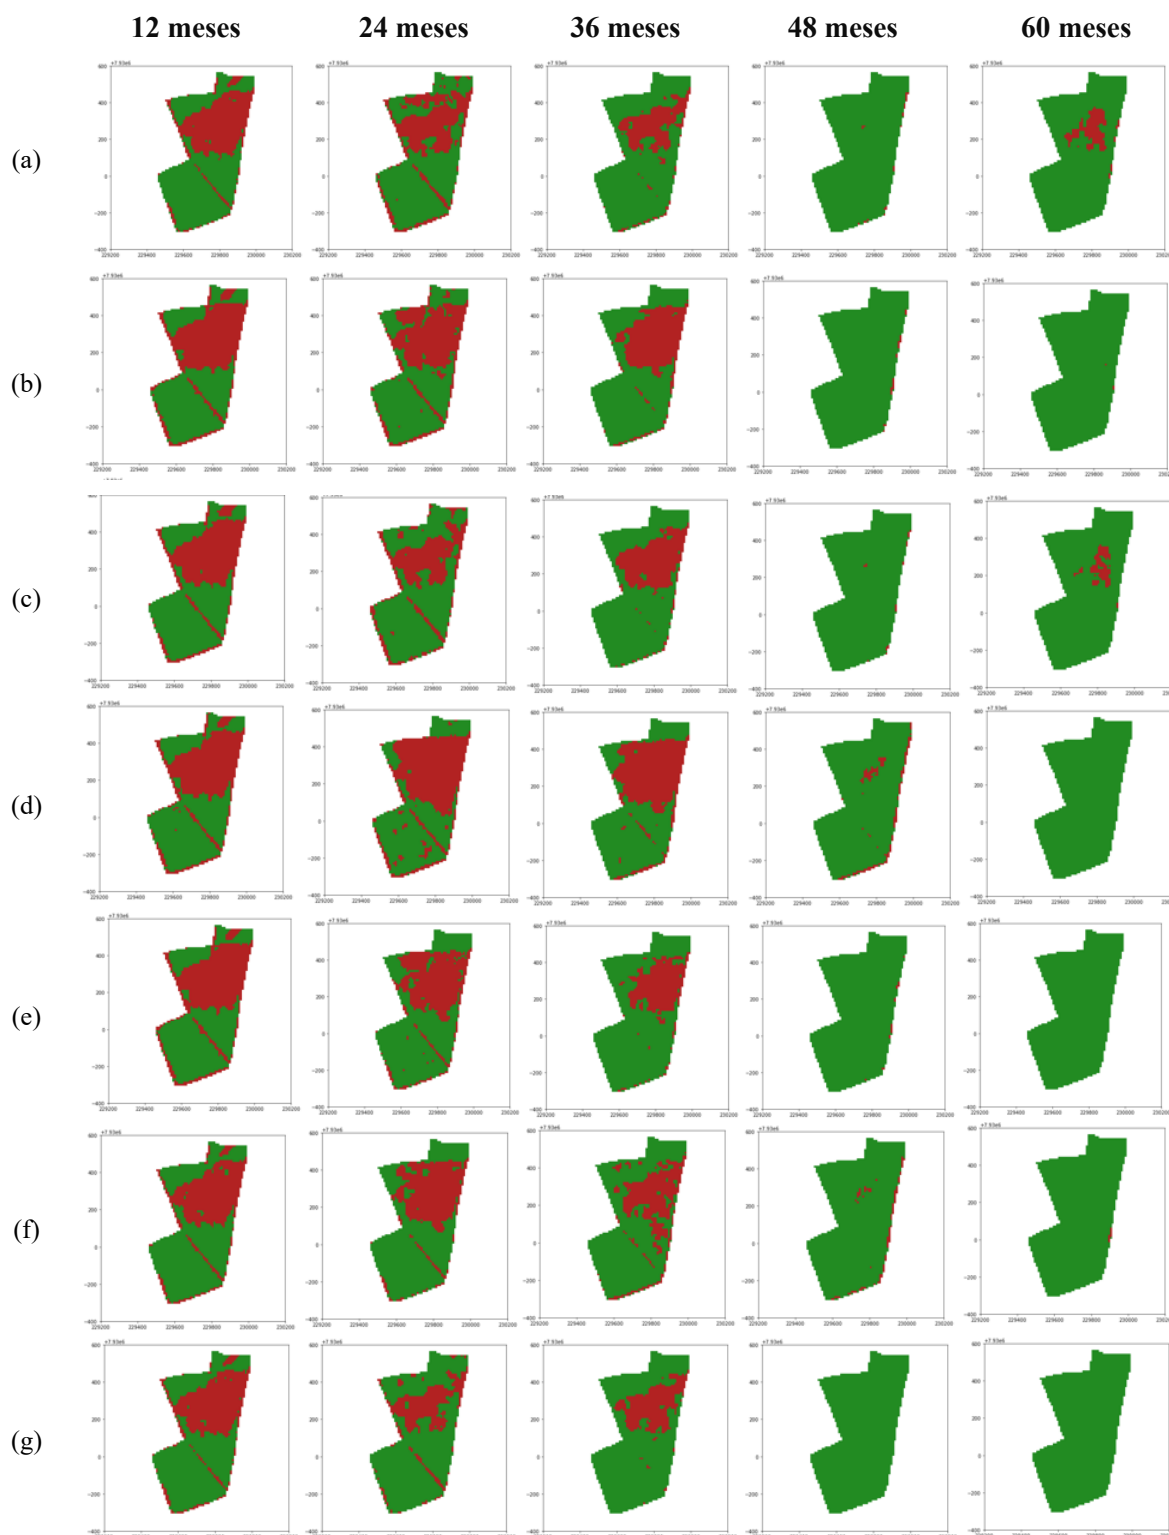
|     |                      | Precision    |           | Recall |           | F1    |           |      |
|-----|----------------------|--------------|-----------|--------|-----------|-------|-----------|------|
|     |                      | Sadio        | Infestado | Sadio  | Infestado | Sadio | Infestado |      |
| (a) | Formação de grãos    | VIS+VH       | 0.98      | 0.97   | 0.99      | 0.93  | 0.98      | 0.95 |
|     |                      | VIS+NIR+VH   | 0.98      | 0.94   | 0.98      | 0.94  | 0.98      | 0.94 |
|     |                      | VIS+RED1+VH  | 1         | 0.92   | 0.97      | 1     | 0.99      | 0.96 |
|     |                      | VIS+RED2+VH  | 1         | 0.98   | 0.99      | 0.99  | 1         | 0.99 |
|     |                      | VIS+RED3+VH  | 0.97      | 1      | 1         | 0.91  | 0.98      | 0.95 |
|     |                      | VIS+RED4+VH  | 0.99      | 0.99   | 1         | 0.98  | 0.99      | 0.98 |
|     |                      | VIS+SWIR1+VH | 0.99      | 0.95   | 0.98      | 0.97  | 0.99      | 0.96 |
|     |                      | VIS+SWIR2+VH | 1         | 0.96   | 0.99      | 1     | 0.99      | 0.98 |
|     |                      | VIS+NDVI+VH  | 0.99      | 0.97   | 0.99      | 0.96  | 0.99      | 0.97 |
|     |                      | Precision    |           | Recall |           | F1    |           |      |
|     |                      | Sadio        | Infestado | Sadio  | Infestado | Sadio | Infestado |      |
| (b) | Maturação dos frutos | VIS+VH       | 1         | 0.98   | 0.99      | 0.99  | 1         | 0.99 |
|     |                      | VIS+NIR+VH   | 0.99      | 0.98   | 0.99      | 0.98  | 0.99      | 0.98 |
|     |                      | VIS+RED1+VH  | 1         | 0.95   | 0.98      | 1     | 0.99      | 0.97 |
|     |                      | VIS+RED2+VH  | 1         | 0.91   | 0.97      | 1     | 0.98      | 0.95 |
|     |                      | VIS+RED3+VH  | 0.99      | 0.99   | 1         | 0.98  | 1         | 0.99 |
|     |                      | VIS+RED4+VH  | 1         | 0.98   | 0.99      | 0.99  | 1         | 0.99 |
|     |                      | VIS+SWIR1+VH | 1         | 0.99   | 1         | 1     | 1         | 0.99 |
|     |                      | VIS+SWIR2+VH | 1         | 0.97   | 0.99      | 1     | 0.99      | 0.98 |
|     |                      | VIS+NDVI+VH  | 0.96      | 0.99   | 1         | 0.88  | 0.98      | 0.93 |
|     |                      | Precision    |           | Recall |           | F1    |           |      |
|     |                      | Sadio        | Infestado | Sadio  | Infestado | Sadio | Infestado |      |
| (c) | Autopoda             | VIS+VH       | 0.93      | 0.96   | 0.99      | 0.78  | 0.96      | 0.86 |
|     |                      | VIS+NIR+VH   | 0.93      | 1      | 1         | 0.77  | 0.96      | 0.87 |
|     |                      | VIS+RED1+VH  | 0.89      | 1      | 1         | 0.64  | 0.94      | 0.78 |
|     |                      | VIS+RED2+VH  | 0.92      | 1      | 1         | 0.72  | 0.96      | 0.84 |
|     |                      | VIS+RED3+VH  | 0.94      | 0.94   | 0.98      | 0.81  | 0.96      | 0.87 |
|     |                      | VIS+RED4+VH  | 0.93      | 0.99   | 1         | 0.78  | 0.96      | 0.87 |
|     |                      | VIS+SWIR1+VH | 0.93      | 1      | 1         | 0.77  | 0.96      | 0.87 |
|     |                      | VIS+SWIR2+VH | 0.94      | 0.97   | 0.99      | 0.79  | 0.96      | 0.87 |
|     |                      | VIS+NDVI+VH  | 0.89      | 0.99   | 1         | 0.64  | 0.94      | 0.77 |
|     |                      | Precision    |           | Recall |           | F1    |           |      |
|     |                      | Sadio        | Infestado | Sadio  | Infestado | Sadio | Infestado |      |
| (d) | Vegetativo           | VIS+VH       | 0.96      | 0.95   | 0.99      | 0.88  | 0.97      | 0.91 |
|     |                      | VIS+NIR+VH   | 0.97      | 0.98   | 0.99      | 0.91  | 0.98      | 0.94 |
|     |                      | VIS+RED1+VH  | 0.99      | 0.94   | 0.98      | 0.97  | 0.98      | 0.95 |
|     |                      | VIS+RED2+VH  | 0.99      | 0.93   | 0.98      | 0.96  | 0.98      | 0.95 |
|     |                      | VIS+RED3+VH  | 0.99      | 0.93   | 0.98      | 0.98  | 0.98      | 0.95 |
|     |                      | VIS+RED4+VH  | 0.97      | 0.97   | 0.99      | 0.91  | 0.98      | 0.94 |
|     |                      | VIS+SWIR1+VH | 0.94      | 1      | 1         | 0.8   | 0.97      | 0.89 |
|     |                      | VIS+SWIR2+VH | 0.94      | 1      | 1         | 0.79  | 0.97      | 0.89 |
|     |                      | VIS+NDVI+VH  | 0.95      | 0.96   | 0.99      | 0.84  | 0.97      | 0.9  |

**Tabela 4** – Cenário 2: Resultados do treinamento considerando a combinação de atributos ópticos e o atributo sumVVVH, separadamente: (a) Formação de Grãos, (b) Maturação dos Frutos, (c) Autopoda, (d) Vegetativo


|     |                      | Precision      |           | Recall |           | F1    |           |      |
|-----|----------------------|----------------|-----------|--------|-----------|-------|-----------|------|
|     |                      | Sadio          | Infestado | Sadio  | Infestado | Sadio | Infestado |      |
|     |                      |                |           |        |           |       |           |      |
| (a) | Formação de grãos    | VIS+VVVH       | 0.99      | 0.94   | 0.98      | 0.98  | 0.99      | 0.96 |
|     |                      | VIS+NIR+VVVH   | 0.96      | 0.97   | 0.99      | 0.87  | 0.97      | 0.92 |
|     |                      | VIS+RED1+VVVH  | 1         | 0.9    | 0.96      | 1     | 0.98      | 0.95 |
|     |                      | VIS+RED2+VVVH  | 0.99      | 0.92   | 0.97      | 0.97  | 0.98      | 0.94 |
|     |                      | VIS+RED3+VVVH  | 1         | 0.89   | 0.96      | 1     | 0.98      | 0.94 |
|     |                      | VIS+RED4+VVVH  | 0.99      | 1      | 1         | 0.96  | 0.99      | 0.98 |
|     |                      | VIS+SWIR1+VVVH | 0.99      | 0.91   | 0.97      | 0.98  | 0.98      | 0.95 |
|     |                      | VIS+SWIR2+VVVH | 1         | 0.96   | 0.98      | 0.99  | 0.99      | 0.97 |
|     |                      | VIS+NDVI+VVVH  | 0.97      | 0.94   | 0.98      | 0.9   | 0.97      | 0.92 |
| (b) | Maturação dos frutos | VIS+VVVH       | 0.99      | 0.99   | 1         | 0.96  | 0.99      | 0.97 |
|     |                      | VIS+NIR+VVVH   | 1         | 0.97   | 0.99      | 1     | 1         | 0.99 |
|     |                      | VIS+RED1+VVVH  | 0.97      | 0.99   | 1         | 0.89  | 0.98      | 0.94 |
|     |                      | VIS+RED2+VVVH  | 1         | 0.96   | 0.98      | 1     | 0.99      | 0.98 |
|     |                      | VIS+RED3+VVVH  | 0.99      | 0.98   | 0.99      | 0.98  | 0.99      | 0.98 |
|     |                      | VIS+RED4+VVVH  | 0.99      | 0.96   | 0.99      | 0.98  | 0.99      | 0.97 |
|     |                      | VIS+SWIR1+VVVH | 1         | 0.99   | 1         | 0.99  | 1         | 0.99 |
|     |                      | VIS+SWIR2+VVVH | 1         | 0.87   | 0.95      | 1     | 0.98      | 0.93 |
|     |                      | VIS+NDVI+VVVH  | 1         | 0.98   | 0.99      | 1     | 1         | 0.99 |
| (c) | Autopoda             | VIS+VVVH       | 0.91      | 1      | 1         | 0.69  | 0.95      | 0.81 |
|     |                      | VIS+NIR+VVVH   | 0.92      | 1      | 1         | 0.75  | 0.96      | 0.86 |
|     |                      | VIS+RED1+VVVH  | 0.93      | 0.94   | 0.98      | 0.77  | 0.96      | 0.85 |
|     |                      | VIS+RED2+VVVH  | 0.92      | 1      | 1         | 0.74  | 0.96      | 0.85 |
|     |                      | VIS+RED3+VVVH  | 0.92      | 1      | 1         | 0.75  | 0.96      | 0.86 |
|     |                      | VIS+RED4+VVVH  | 0.94      | 0.93   | 0.98      | 0.8   | 0.96      | 0.86 |
|     |                      | VIS+SWIR1+VVVH | 0.92      | 1      | 1         | 0.79  | 0.96      | 0.85 |
|     |                      | VIS+SWIR2+VVVH | 1         | 0.91   | 1         | 0.71  | 0.95      | 0.83 |
|     |                      | VIS+NDVI+VVVH  | 0.89      | 1      | 1         | 0.62  | 0.94      | 0.76 |
| (d) | Vegetativo           | VIS+VVVH       | 0.96      | 0.9    | 0.97      | 0.89  | 0.97      | 0.89 |
|     |                      | VIS+NIR+VVVH   | 0.94      | 1      | 1         | 0.8   | 0.97      | 0.89 |
|     |                      | VIS+RED1+VVVH  | 0.96      | 0.92   | 0.97      | 0.89  | 0.97      | 0.9  |
|     |                      | VIS+RED2+VVVH  | 0.94      | 0.95   | 0.98      | 0.82  | 0.96      | 0.88 |
|     |                      | VIS+RED3+VVVH  | 0.98      | 0.95   | 0.98      | 0.93  | 0.98      | 0.94 |
|     |                      | VIS+RED4+VVVH  | 0.94      | 1      | 1         | 0.8   | 0.97      | 0.89 |
|     |                      | VIS+SWIR1+VVVH | 0.94      | 1      | 1         | 0.8   | 0.97      | 0.89 |
|     |                      | VIS+SWIR2+VVVH | 0.99      | 0.88   | 0.96      | 0.97  | 0.97      | 0.93 |
|     |                      | VIS+NDVI+VVVH  | 0.92      | 1      | 1         | 0.74  | 0.96      | 0.85 |

## APÊNDICE D – RESULTADO DA DETECÇÃO ESPAÇO-TEMPORAL DE NEMATOIDES NA CULTURA CAFEEIRA A PARTIR DA INTEGRAÇÃO DE DADOS ÓPTICOS E SAR

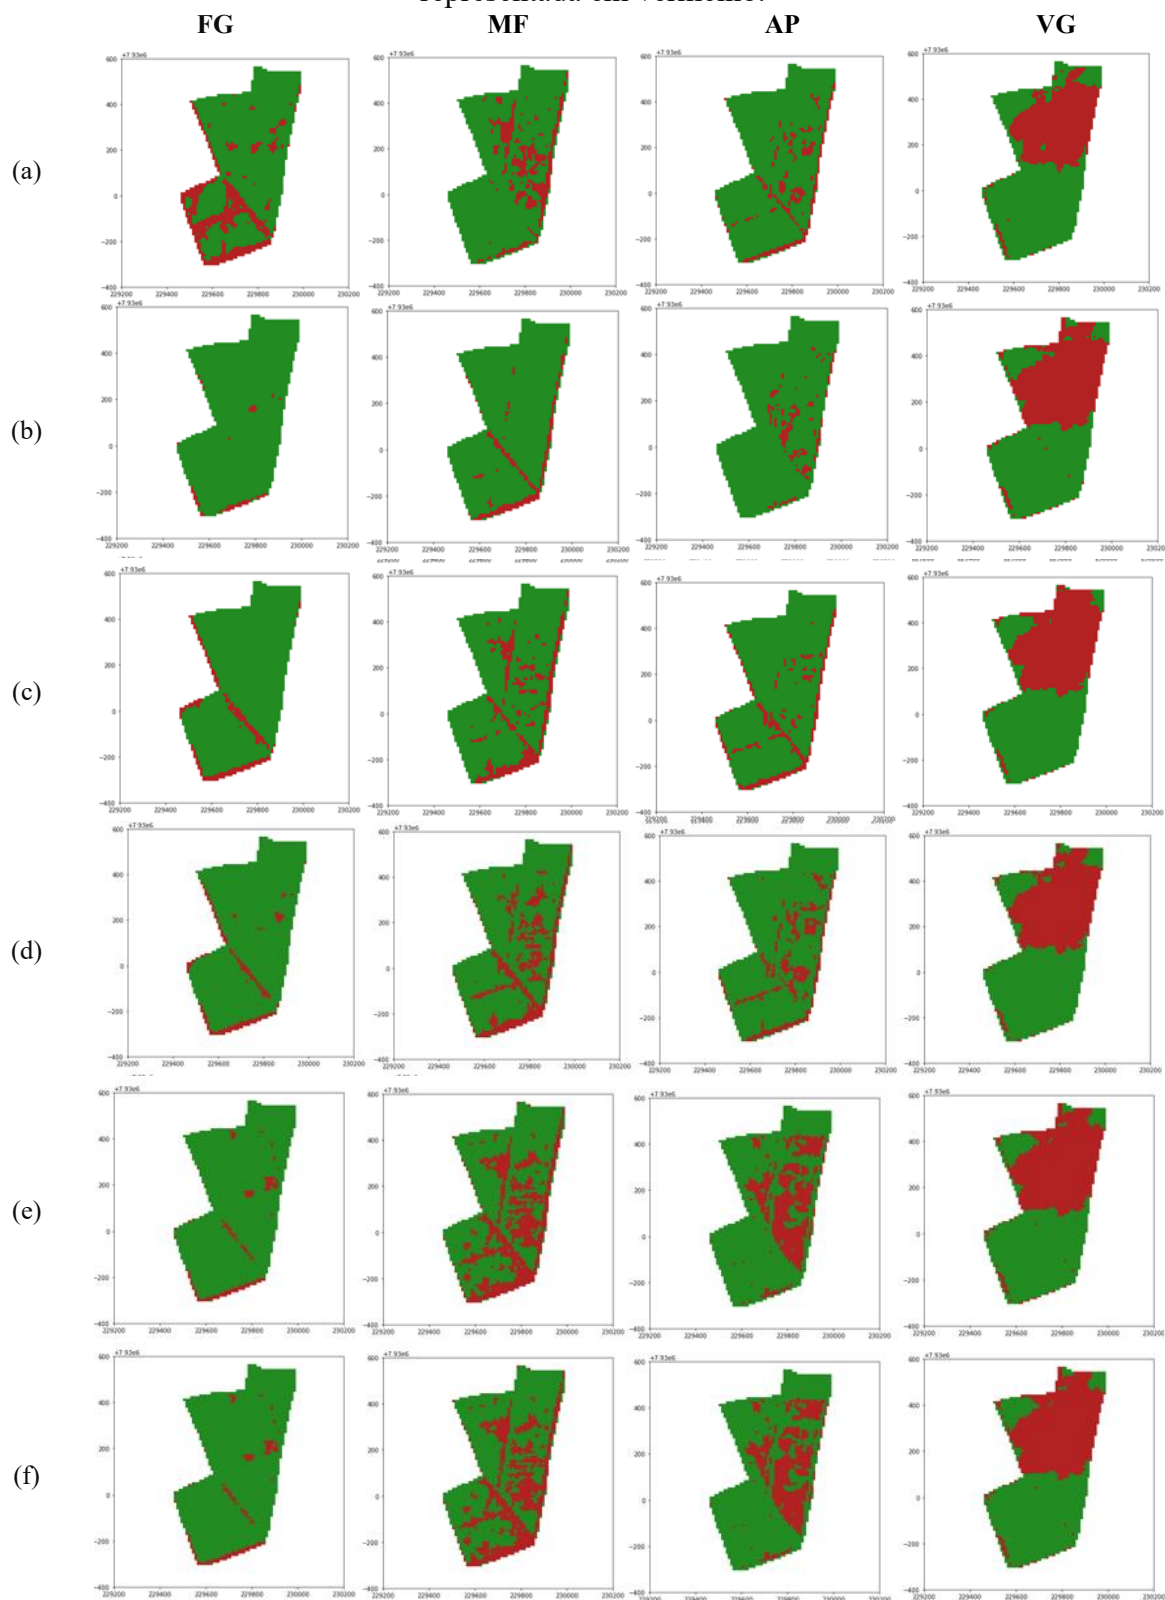
**Figura 1** - Detecção de área infestada por nematoides a partir da combinação de dados ópticos e polarização  $\sigma^0$ VH: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



**Figura 1** - Detecção de área infestada por nematoides a partir da combinação de dados ópticos e polarização  $\sigma^0$  VH: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



**Figura 2** – Detecção de área infestada por nematoides a partir da combinação de dados ópticos e polarização  $\sigma^0$ VH por fase fenológica: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.



**Figura 2** – Detecção de área infestada por nematoides a partir da combinação de dados ópticos e polarização  $\sigma^0$ VH por fase fenológica: (a) VIS, (b) VIS+NIR, (c) VIS+RED1, (d) VIS+RED2, (e) VIS+RED3, (f) VIS+RED4, (g) VIS+SWIR1, (h) VIS+SWIR2 e (i) VIS+NDVI. A classe sadio (S) é representada em verde e a classe infestado (I) é representada em vermelho.

