



PEDRO ARTHUR DE AZEVEDO SILVA

**SENSORIAMENTO REMOTO MULTIESPECTRAL PASSIVO
E ATIVO PARA O MONITORAMENTO DO CAFÉ ARÁBICA**

**LAVRAS - MG
2020**

PEDRO ARTHUR DE AZEVEDO SILVA

**SENSORIAMENTO REMOTO MULTIESPECTRAL PASSIVO E ATIVO PARA O
MONITORAMENTO DO CAFÉ ARÁBICA**

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

Prof. Dr. Marcelo de Carvalho Alves
Orientador

Prof. Dr. Fábio Moreira da Silva
Coorientador

**LAVRAS - MG
2020**

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

Silva, Pedro Arthur de Azevedo.

Sensoriamento remoto multiespectral passivo e ativo para o monitoramento do café arábica / Pedro Arthur de Azevedo Silva. - 2020.

73 p. : il.

Orientador(a): Marcelo de Carvalho Alves.

Coorientador(a): Fábio Moreira da Silva.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2020.

Bibliografia.

1. Coffea arabica L. 2. RADAR de abertura sintética. 3. Processamento digital de imagens. I. Alves, Marcelo de Carvalho. II. Silva, Fábio Moreira da. III. Título.

PEDRO ARTHUR DE AZEVEDO SILVA

**SENSORIAMENTO REMOTO MULTIESPECTRAL PASSIVO E ATIVO PARA O
MONITORAMENTO DO CAFÉ ARÁBICA**

**PASSIVE AND ACTIVE MULTISPECTRAL REMOTE SENSING FOR ARABIC
COFFEE MONITORING**

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

APROVADO em 22 de janeiro de 2020.

Prof. Dr. Marcelo de Carvalho Alves

Dra. Vanessa Castro Figueiredo

Prof. Dr. André Hirsch

UFLA/DEA

EPAMIG/CETP

UFSJ/DCIAG

Prof. Dr. Marcelo de Carvalho Alves
Orientador

**LAVRAS - MG
2020**

AGRADECIMENTOS

Agradeço todo o apoio recebido por todos, antes e durante o período de pós-graduação.

Agradeço aos meus familiares e amigos, por todo auxílio, paciência e acompanhamento durante todos os momentos vividos até então.

À todos os colegas de laboratório e departamento, por todo suporte profissional e emocional.

Ao orientador Prof. Dr. Marcelo de Carvalho Alves, não apenas pela orientação, paciência e disposição para ajudar, mas, também, pela amizade e por acreditar em minha capacidade acadêmica e profissional.

Aos meus demais professores, por todas as instruções, sempre presentes em momentos de dúvidas e principais responsáveis pelo meu encanto pelo meio acadêmico.

À todos os funcionários da Universidade Federal de Lavras.

À Universidade Federal de Lavras, especialmente ao Departamento de Engenharia Agrícola.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Muito obrigado a todos.

“Estude a ciência da arte. Estude a arte da ciência. Desenvolva seus sentidos e, especialmente, aprenda a ver. Perceba que tudo se conecta a todo o resto.”
(Leonardo da Vinci)

RESUMO

Monitorar do desenvolvimento de uma área agrícola, com o auxílio de imagens obtidas de sensores ativos de Detecção e Determinação da Distância por Ondas de Rádio (RADAR) é uma alternativa para superar tais barreiras tão presentes no cenário do monitoramento orbital. Devido às características desse tipo de sensor, é possível registrar propriedades do alvo terrestre, independente da ocorrência de nuvens entre o alvo em questão e o sensor orbital, sendo que essa ocorrência de nuvens apresenta frequência considerável em áreas cafeeiras, devido às condições edafoclimáticas recomendadas para realizar o cultivo do café. Verificando que sensores orbitais ativos são subutilizados para o monitoramento agrícola, e em especial para a cafeicultura, o presente trabalho objetivou avaliar a utilização dos dados provenientes de sensores orbitais passivos e ativo para o monitoramento de áreas cafeeiras, correlacionando seus registros espectrais com dados obtidos em campo. Para a realização do estudo, o banco de dados foi preparado com informações extraídas das imagens de sensores passivos, ativo, além de informações coletadas *in situ*, com o objetivo de identificar padrões espectrais e temporais de lavouras cafeeiras, avaliando-os por meio de técnicas de geoprocessamento e estatística uni e multivariada. A partir das abordagens adotadas em cada foco de estudo, foi possível gerar modelos e validá-los de forma a introduzir uma nova metodologia para o monitoramento do crescimento e desenvolvimento dos parques cafeeiros, independente das condições climáticas apresentadas nas regiões de estudo. Foi possível também, verificar a aplicação do uso de imageamento por meio de RADAR para o registro do comportamento espectro-temporal do café. Tal registro promoveu uma nova possibilidade de mapeamento e monitoramento de lavouras cafeeiras sem interferência significativa de nebulosidade local, eliminando as principais dificuldades que existem atualmente como gargalo no avanço do sensoriamento remoto da cafeicultura.

Palavras-Chave: *Coffea arabica* L. RADAR de abertura sintética. Processamento digital de imagens.

ABSTRACT

Monitoring the development of an agricultural area, with the help of images obtained from Radio Detection and Ranging (RADAR) active sensors, is an alternative to overcome such barriers in orbital monitoring scenario. Due to the characteristics of this type of sensor, it is possible to record properties of the terrestrial target, regardless of the occurrence of clouds between the target in question and the orbital sensor. This clouds occurrence is considerable common in coffee areas, due to the recommended edaphoclimatic conditions to perform its cultivation. Verifying that active orbital sensors are underused for agricultural monitoring, and especially for coffee growing, the present study aimed to evaluate the use of passive and active orbital sensors data for coffee areas monitoring, correlating their spectral records with field data. For this study, the database was prepared with information extracted from the images of passive and active sensors, as well as field data, in order to identify spectral and temporal patterns of coffee crops, evaluating them through geoprocessing techniques combined with univariate and multivariate statistics analyses. From the approaches adopted in each study focus, it was possible to generate models and validate them in order to introduce a new growth and development monitoring methodology for coffee parks, regardless of the climatic conditions presented in the study regions. It was also possible to verify the RADAR imaging application to record the spectrum-temporal behavior of coffee. Such result promoted a new possibility of coffee crops mapping and monitoring without significant interference of local cloudiness, eliminating the main difficulties that currently exist as a bottleneck in the advance of remote sensing of coffee growing.

Palavras-Chave: *Coffea arabica* L. Synthetic aperture RADAR. Digital image processing.

SUMÁRIO

	CAPÍTULO 1 Introdução geral	9
1	INTRODUÇÃO	9
2	REFERENCIAL TEÓRICO	10
2.1	Cultura do Café	10
2.2	Sensoriamento Remoto	13
2.2.1	Uso de Sensor Orbital Passivo na Agricultura	13
2.2.2	Uso de Sensor Orbital Ativo de Abertura Sintética na Agricultura	14
3	CONSIDERAÇÕES GERAIS	17
	REFERÊNCIAS	17
	 CAPÍTULO 2 Estimativa da produtividade do cafeeiro em pivô central por meio de imagens landsat-8 considerando o efeito de sombreamento nas entrelinhas de plantio	 20
1	INTRODUÇÃO	20
2	MATERIAL E MÉTODOS	21
2.1	Área de Estudo	21
2.2	Obtenção de dados <i>in situ</i>	22
2.3	Obtenção de dados radiométricos de plataforma orbital	23
2.4	Análises Estatísticas	26
3	RESULTADOS E DISCUSSÃO	27
4	CONCLUSÕES	35
	REFERÊNCIAS	36
	 CAPÍTULO 3 Obtenção de assinatura de EVI para lavouras cafeeiras sob diferentes sistemas de irrigação por meio de análise de séries temporais	 40
1	INTRODUÇÃO	40
2	MATERIAL E MÉTODOS	42
2.1	Área de Estudo	42
2.2	Dados radiométricos de plataforma orbital	43
2.3	Análise de Séries Temporais	43
3	RESULTADOS E DISCUSSÃO	45
4	CONCLUSÕES	53
	REFERÊNCIAS	54
	 CAPÍTULO 4 Monitoramento por meio de NDVI _{SAR} de polarização dupla para áreas cafeeiras sob diferentes sistemas de irrigação	 57
1	INTRODUÇÃO	57
2	MATERIAL E MÉTODOS	59
2.1	Área de Estudo	59
2.2	Dados Orbitais	61
2.3	Análises Estatísticas	64
3	RESULTADOS E DISCUSSÃO	65
4	CONCLUSÃO	71
	REFERÊNCIAS	71

CAPÍTULO 1

Introdução Geral

1 INTRODUÇÃO

Considerando a importância da cafeicultura para a economia global, muitos estudos são conduzidos com o objetivo de identificar, monitorar e até mesmo prever o desenvolvimento das lavouras cafeeiras. Para que esses estudos se tornem viáveis, em muitos casos, utilizam-se sensores orbitais para cobrir áreas extensas de produção de café e, assim, obter dados físicos para executar pesquisas diversas sobre a cultura e suas interações com o agroecossistema (TRABAQUINI *et al.*, 2011). Atualmente, para realizar o mapeamento e monitoramento remoto do café são utilizados dados de sensores orbitais passivos, provenientes de satélites imageadores como, por exemplo, o *Landsat-8*.

O uso de dados desses sensores passivos, apesar de apresentarem resoluções espaciais e espectrais consideravelmente boas, pode ser prejudicado pela ocorrência de nuvens, o que resulta em ruídos nas imagens, impedindo a correta caracterização dos alvos terrestres. Na maioria das vezes, os estudos desconsideram os sensores ativos e se concentram apenas no uso de sensores passivos, que podem comprometer a captura de informações devido a condições adversas de campo, o que dificulta a aquisição de dados de qualidade (ROSA *et al.*, 2010).

Com o uso de sistemas de sensores orbitais ativos como, por exemplo, o satélite *Sentinel-1*, há independências de ocorrências de nuvens e de disponibilidade de iluminação natural, pois os sensores emitem e recebem ondas eletromagnéticas com propriedades controladas, como o comprimento da onda, frequência e polarização (VELOSO *et al.*, 2017). O efeito de emitir a própria energia eletromagnética, com parâmetros controlados, permite o mapeamento de regiões de interesse em momentos que com os sistemas passivos há dificuldade ou, não se consegue realizar o registro de informações do alvo terrestre (WOODHOUSE, 2006).

Com base nas características desse tipo de sensor, é possível registrar propriedades do alvo terrestre, independente da ocorrência de nuvens entre o alvo em questão e o sensor orbital, sendo que essa ocorrência de nuvens apresenta frequência considerável em áreas cafeeiras, devido à altitude e a precipitação características dessas áreas. Dessa forma, nota-se a necessidade de determinação de uma metodologia alternativa para a realização de trabalhos de monitoramento remoto de lavouras cafeeiras, visando que os futuros trabalhos de monitoramento e tomada de decisão não sejam prejudicados pelas próprias condições naturais das áreas estudadas.

Com a utilização de sensores ativos para o monitoramento de lavouras cafeeiras, pode-se obter uma abordagem inédita e passível de solucionar problemas dos atuais métodos de sensoriamento remoto, com baixo custo, devido à disponibilidade gratuita dos dados e dos *softwares* necessários para a aplicação da técnica. Diante do exposto, a presente pesquisa buscou avaliar a utilização dos dados provenientes de sensores orbitais passivos e ativo para o monitoramento de áreas cafeeiras, correlacionando seus registros espectrais com dados obtidos em campo.

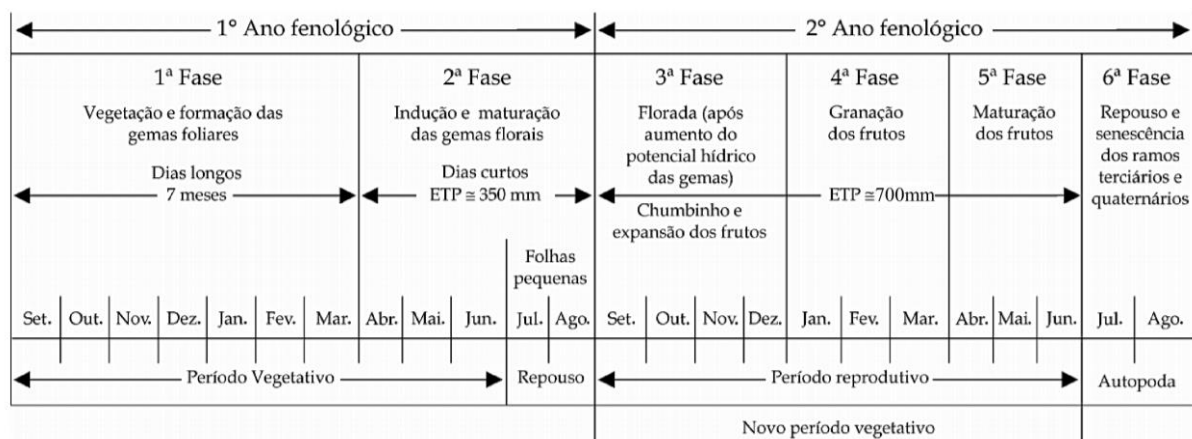
2 REFERENCIAL TEÓRICO

2.1 Cultura do café

A importância socioeconômica mundial do cultivo de café é observada pelo fato do produto ser uma *commodity* de elevada influência sobre a movimentação da bolsa de valores. Dessa forma, países que demonstram maior controle e acurácia quanto a estimativa da produção de suas lavouras cafeeiras, tem um alto potencial de planejamento econômico, o que impacta diretamente em sua estrutura sociopolítica e administrativa (MIRANDA *et al.*, 2014).

É necessário conhecer e registrar as fases fenológicas do cafeeiro para garantir o correto acompanhamento do desenvolvimento da cultura, de forma a intervir de acordo com a necessidade da planta em seus diferentes estádios de crescimento e produção. Pereira *et al.* (2008) registraram a diferença entre as fases fenológicas e suas peculiaridades e necessidades de condições climáticas (FIGURA 1.1), que são influenciadas pelas características do local e época em que o cafeeiro se encontra.

Figura 1.1 - Ciclo fenológico da planta do cafeeiro.




Fonte: Pereira *et al.* (2008).


Em essência, o ciclo fenológico do cafeeiro se separa em dois anos distintos, onde o primeiro é caracterizado pela fase vegetativa, marcado pelo desenvolvimento de folhas e gemas, e o segundo ano é caracterizado pela fase reprodutiva, marcado pelo desenvolvimento das flores e dos frutos (CAMARGO; CAMARGO, 2001).

Em maior detalhamento, Pezzopane *et al.* (2003), realizou estudos que identificaram e descreveram os diferentes estádios fenológicos do cafeeiro em 12 estádios (FIGURA 1.2).

Figura 1.2 - Imagens ilustrativas das diferenças características de cada fase fenológica do cafeeiro.



0 – Gema dormente



1 – Gema entumescida




2 – Abotoado




3 – Florada




4 – Pós-florada




5 – Chumbinho




6 – Expansão dos frutos




7 – Grão verde




8 – Verde cana



9 – Cereja



10 – Passa



11 – Seco

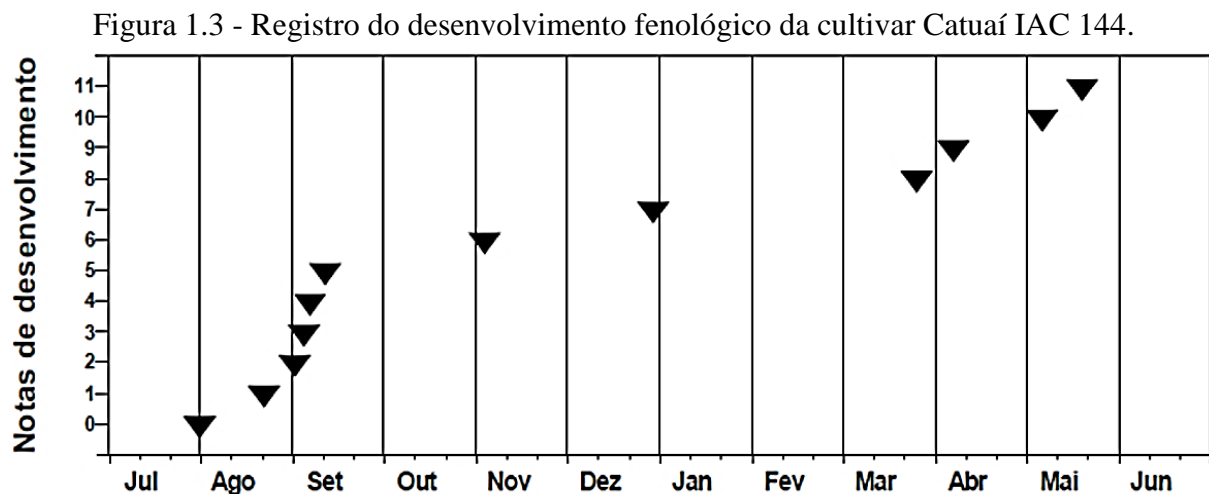
Fonte: Pezzopane *et al.* (2003).

O primeiro estágio é caracterizado pela dormência das gemas (0) nos nós dos ramos plagiotrópicos. Após esse estágio, que marca o final do ano vegetativo, as gemas entumescem (1), os botões florais crescem (2) até que flores se abram (3).

Após a fase de florada ocorre a queda das pétalas (4) devido a fecundação, dando início a formação dos frutos na fase de “chumbinho” (5). Após essa fase, os frutos se expandem (6) e, com a formação do endosperma, segue para a fase de grão verde (7).

Caracterizando o período de maturação, iniciado pela fase de “verde cana” (8), os frutos começam a mudar para sua cor característica, evoluindo até o estágio “cereja” (9) no qual, normalmente, é realizada a colheita. Caso os frutos continuem na planta, eles começam a perder umidade (10) até atingir o estágio “seco” (11) (PEZZOPANE *et al.*, 2003).

Os doze estádios citados foram registrados em suas respectivas datas de mudança verificada em campo, os quais apresentaram concordância com o período descrito por Camargo e Camargo (2001) (FIGURA 1.3).



Fonte: Pezzopane *et al.* (2003).

Apesar de diferentes fatores bióticos e abióticos poderem influenciar significativamente de forma negativa no desenvolvimento fenológico e na produção final do cafeeiro, a ocorrência de más práticas de manejo, muitas vezes por falta de um sistema de tomada de decisão, ainda é um fator considerável que impede o alcance da produção máxima regional. Essas práticas inadequadas acabam acontecendo pela adoção de uma metodologia defasada de monitoramento das lavouras de café e, dessa forma, podem acabar resultando no desperdício de tempo e recursos do produtor (WANG *et al.*, 2015).

Contrastando com a lógica que diversos estudos determinaram, o monitoramento de todo o desenvolvimento vegetativo do café no lugar do acompanhamento direto do período

reprodutivo é um método que pode levar ao aumento da eficiência de previsão de safra das lavouras cafeeiras, visto que o desenvolvimento do café em sua fase vegetativa é altamente correlacionado com sua produtividade e ainda permite ao produtor tomar decisões adequadas, em tempo hábil, para garantir a produção esperada ao final do ciclo (DE CARVALHO *et al.*, 2010).

Diante da necessidade ressaltada por diferentes autores, existe uma crescente demanda pelo desenvolvimento, especialização e disseminação de novas técnicas de sensoriamento remoto para o monitoramento das lavouras de café, visto que temos avanços das geotecnologias, porém ainda não foram exploradas de forma satisfatória (FIGUEIREDO *et al.*, 2017).

2.2 Sensoriamento Remoto

Apesar da complexidade na utilização do sensoriamento remoto para as lavouras de café, cujos dados podem ser influenciados por diferentes fatores bióticos e abióticos, a aquisição de padrões espectrais da cultura é uma técnica extremamente útil, uma vez que há a dificuldade para a aquisição de dados *in situ* numa escala regional (BERNARDES *et al.*, 2012).

Dessa forma, utilizar técnicas de sensoriamento remoto para monitorar as lavouras de café é um método altamente promissor, permitindo detectar características fisiológicas quanto ao desenvolvimento das plantas em tempo hábil.

2.2.1 Uso de Sensor Orbital Passivo na Agricultura

O uso de geoprocessamento e processamento de imagens digitais, juntamente a dados de sensores imageadores passivos, é uma poderosa ferramenta para realizar levantamentos de dados ambientais e alimentar bancos de dados, objetivando a realização de estudos agrícolas e a definição de tomada de decisões (TRABAQUINI *et al.*, 2011).

Os produtores sempre necessitaram de informações sobre as condições de desenvolvimento vegetal da lavoura e do ambiente em seu entorno, de forma dinâmica e contínua, para que seus trabalhadores possam determinar a melhor estratégia de cultivo.

Diante dessa necessidade foi proposto o desenvolvimento de análises espectrais levando em consideração os dados de refletância registrados pelos sensores passivos disponíveis na época. Essas análises levaram a criação de índices de vegetação que permitem avaliar o vigor de desenvolvimento da vegetação presente na região (ROUSE *et al.*, 1973).

A utilização de índices foi um avanço no campo do monitoramento agrícola, sendo uma técnica amplamente usada desde sua criação. Os índices permitem avaliar grandes regiões de interesse, espacializando informações sobre desenvolvimento de diferentes culturas,

possibilitando até mesmo definir suas diferentes fases fenológicas (CHEMURA; MUTANGA; DUBE, 2017; GAO, 1996).

Contudo, mesmo com a eficiência do uso de índices para o monitoramento e previsão de safra de diferentes culturas, a aquisição de dados de imagens orbitais e, conseqüentemente, as informações desses índices, pode ser prejudicada pela alta probabilidade de ocorrência de nuvens em regiões de interesse, o que, por muitas vezes, impede que sensores passivos registrem os dados de refletância dos alvos terrestres durante as diferentes etapas do ciclo de desenvolvimento da cultura (ROSA *et al.*, 2010).

2.2.2 Uso de Sensor Orbital Ativo de Abertura Sintética na Agricultura

Satélites de sensores óticos passivos sempre foram utilizados para monitorar a produção agrícola em larga escala e em diversos países, mesmo com o problema principal da ocorrência de nuvens. Apesar das metodologias já estabelecidas para atender tais demandas, a utilização de dados de sensores ativos tem crescido, pois esses sensores permitem um acompanhamento mais completo, independente das condições climáticas presentes na região de estudo.


Pesquisas realizadas corroboram com essa ideia do uso de dados de sensores ativos e concluem que, além de realizar o monitoramento completo de lavouras, esses dados podem ser utilizados para preencher falhas dos sensores passivos, permitindo completar dados faltantes em bancos de dados, onde os sensores passivos tiveram problemas por ocorrência de nuvens em suas cenas (VELOSO *et al.*, 2017).

O monitoramento de culturas de verão, ou culturas presentes em regiões tropicais, se torna mais eficaz ao utilizar satélites com imageamento ativo. Adicionalmente, os sinais das ondas de rádio são influenciados principalmente pelas condições do solo e a fenologia da planta em questão, com baixa interferência das condições atmosféricas. Logo, é possível obter informações sobre a cultura de interesse, com alto detalhamento, mesmo em condições que os sensores passivos nem mesmo conseguiriam imagear (BARGIEL, 2017; SILVA *et al.*, 2012; TORBICK *et al.*, 2017; ZHANG *et al.*, 2018).

A forma como o sinal é rebatido pela superfície mapeada pode variar de acordo com a topografia superficial ou, em outras palavras, a rugosidade relativa em comparação ao comprimento da onda emitida. Caso a superfície apresente uma rugosidade mais suave, podendo ser considerada relativamente lisa, o sinal poderá ser rebatido de forma especular, sendo redirecionando para longe do receptor, que registrará uma intensidade baixa, ou não registrará nenhum sinal de retorno (PONZONI, 2012).

A superfície que apresentar uma rugosidade relativa mais acidentada poderá causar um efeito de retroespalhamento difuso, no qual parte da onda rebatida retorna em direção ao receptor, enquanto outra parte é rebatida para diferentes direções. Dessa forma, o sinal registrado apresentará uma intensidade de nível médio, dependendo do padrão topográfico superficial. Quando o sinal intercepta alguma estrutura com sentido ortogonal a superfície, acontece a reflexão de canto, na qual o sinal é rebatido duas vezes em sequência, retornando diretamente para o sensor que, por sua vez, registrará alta intensidade do sinal recebido (FIGURA 1.4).

Figura 1.4 - Tipos de retroespalhamento: Especular (A), difuso (B) e reflexão de canto (C).



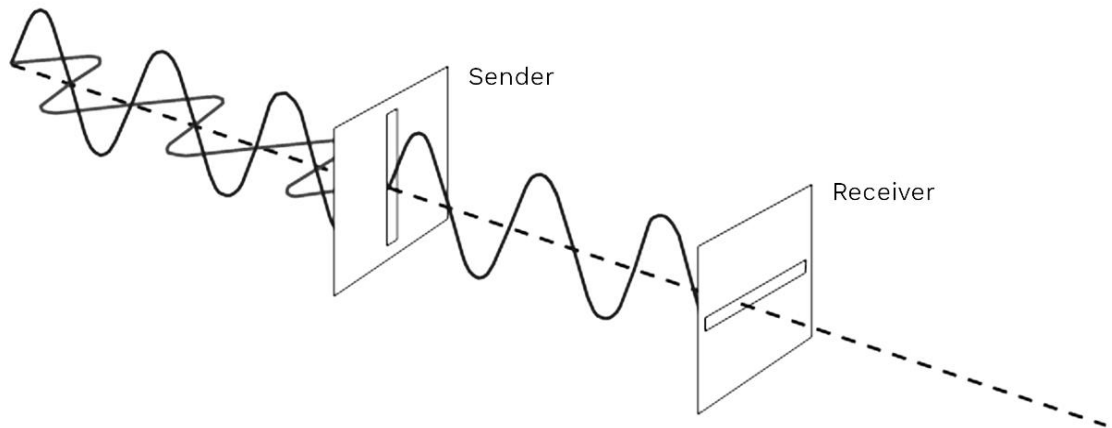
Fonte: Ponzoni *et al.* (2012).

Dependendo da formação do alvo, caso apresente muitas ramificações ou estruturas de orientações de crescimento variadas, como o caso de árvores e seus galhos, o sinal tende a ser rebatido diversas vezes, fazendo com que o sensor registre média intensidade do sinal ao retornar para o receptor (WOODHOUSE, 2006).

Com os sensores ativos pode-se selecionar a polaridade das ondas eletromagnéticas emitidas e, ao atingir os alvos terrestres, as ondas podem interagir com o material de composição do alvo, o que pode modificar a sua polaridade antes de rebater o sinal de volta ao sensor (RICHARDS, 2009).

A polaridade da onda emitida pode ser definida como horizontal ou vertical ao passar por um filtro polarizado, e é altamente influenciada pela constante dielétrica dos materiais que compõem os alvos (FIGURA 1.5).

Figura 1.5 - Polarização da onda eletromagnética.



Fonte: ESA (2017) adaptado de Keith Gibbs (2013).

A constante dielétrica, ou permissividade elétrica, não apresenta valor constante para os objetos e seus formatos, mas sim, apresenta valores similares para materiais que apresentem tendências semelhantes de interação com ondas eletromagnéticas.

Quanto maior for o valor dessa constante, maior a influência do material que compõe o alvo, sobre a troca da polaridade do sinal. Dessa forma, alvos compostos por materiais com essa característica, como folhas ou outros corpos com alto teor de água e/ou sais solubilizados, tendem a inverter a polaridade do sinal emitido e, conseqüentemente, serão detectados nas imagens que registram sinais com polaridade cruzada (RICHARDS, 2009; WOODHOUSE, 2006).

Mesmo com a possibilidade de imageamento durante períodos nublados, essa característica não é a única vantagem dos sensores ativos. O uso de imagens provenientes de sensores ativos é bastante promissor, apresentando baixa porcentagem de confusão por parte de algoritmos classificadores e até mesmo apresentando dados de previsão de safras com elevada acurácia (CLAUSS; OTTINGER; KUENZER, 2018; FERRANT *et al.*, 2017; MONTI-GUARNIERI; GIUDICI; RECCHIA, 2017; SETIYONO *et al.*, 2018).

No contexto do monitoramento das áreas cafeeiras, pode-se notar que apesar dos diferentes trabalhos já realizados, ainda há uma demanda de novas técnicas para acompanhar todo o ciclo fenológico da cultura, independentemente do local ou condições climáticas. Os dados disponibilizados por meio de RADAR se apresentam como uma ferramenta promissora para atender essa demanda, mas estudos ainda devem ser conduzidos para determinar as melhores técnicas e metodologias para alcançar esse objetivo.

3 CONSIDERAÇÕES GERAIS

O presente estudo apresenta três abordagens realizadas visando alcançar o objetivo geral de avaliar a utilização dos dados provenientes de sensores orbitais passivos e ativo para o monitoramento de áreas cafeeiras. As diferentes abordagens utilizaram de sistemas sensores orbitais passivos *Landsat-8*, *Terra* e *Sentinel-2*, além do sistema sensor ativo *Sentinel-1*.

Os capítulos seguintes apresentam as diferentes abordagens aplicadas com seus objetivos específicos, os quais se resumem, sequencialmente, em (1) correlacionar dados de campo de produtividade com os dados espectrais do cafeeiro obtido a partir do *Landsat-8*, (2) obter assinaturas espectro-temporal de EVI por meio de dados do satélite *Terra* para lavouras cafeeiras sob diferentes sistemas de irrigação e (3) avaliar o monitoramento de lavouras cafeeiras sob diferentes sistemas de irrigação, utilizando índices espectrais vegetativos provenientes do sistema sensor passivo *Sentinel-2* e do sistema sensor ativo *Sentinel-1*.

De forma geral, ao concluir os estudos realizados, observou-se que os índices espectrais apresentaram maior correlação com dados de produtividade obtidos em campo, se comparados as bandas espectrais apenas. Além disso, a aplicação de técnicas de análise de séries temporais em séries de índice de vegetação pode ser implementada em sistemas de alerta e tomada de decisão, pois permitiram detectar subdesenvolvimento do cafeeiro, indicando ocorrências de pragas e doenças presentes nas lavouras estudadas.

Entretanto, para que esse método seja aplicado de forma satisfatória, é necessário que os dados utilizados no ajuste do modelo apresentem constância temporal, o que por muitas vezes os sensores passivos não permitem atender tal requisito. Essa barreira pode ser contornada pelo uso de um índice espectral vegetativo por meio de RADAR de abertura sintética (NDVI_{SAR}), pois o uso desse índice demonstrou potencial para ser aplicado em estudos que demandem constância temporal para regiões cafeeiras afetadas por alta frequência de nebulosidade, com caracterização satisfatória das lavouras cafeeiras, independente do sistema de irrigação implementado.

REFERÊNCIAS

BARGIEL, D. A new method for crop classification combining time series of radar images and crop phenology information. **Remote Sensing of Environment**, v. 198, p. 369–383, 2017.

BERNARDES, T. et al. Monitoring biennial bearing effect on coffee yield using MODIS remote sensing imagery. **International Geoscience and Remote Sensing Symposium (IGARSS)**, v. 5, p. 3760–3763, 2012.

CAMARGO, Â. P. DE; CAMARGO, M. B. P. DE. Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil. **Bragantia**, v. 60, n. 1, p. 65–68, 2001.

CHEMURA, A.; MUTANGA, O.; DUBE, T. Integrating age in the detection and mapping of incongruous patches in coffee (*Coffea arabica*) plantations using multi-temporal Landsat 8 NDVI anomalies. **International Journal of Applied Earth Observation and Geoinformation**, v. 57, p. 1–13, 2017.

CLAUSS, K.; OTTINGER, M.; KUENZER, C. Mapping rice areas with Sentinel-1 time series and superpixel segmentation. **International Journal of Remote Sensing**, v. 39, n. 5, p. 1399–1420, 2018.

DE CARVALHO, A. M. et al. Correlação entre crescimento e produtividade de cultivares de café em diferentes regiões de Minas Gerais, Brasil. **Pesquisa Agropecuária Brasileira**, v. 45, n. 3, p. 269–275, 2010.

FERRANT, S. et al. Detection of irrigated crops from Sentinel-1 and Sentinel-2 data to estimate seasonal groundwater use in South India. **Remote Sensing**, v. 9, n. 11, 2017.

FIGUEIREDO, V. C. et al. Análise da variabilidade espacial da força de desprendimento dos frutos do cafeeiro sob pivô central. **Coffee Science**, v. 12, n. 2, p. 84–92, 2017.

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, 1996.

MIRANDA, J. M. et al. Modelo matemático para previsão da produtividade do cafeeiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 4, p. 353–361, 2014.

MONTI-GUARNIERI, A.; GIUDICI, D.; RECCHIA, A. Identification of C-band radio frequency interferences from Sentinel-1 data. **Remote Sensing**, v. 9, n. 11, p. 1–11, 2017.

PEZZOPANE, J. R. M. et al. Escala para avaliação de estádios fenológicos do cafeeiro arábica. **Bragantia**, v. 62, n. 3, p. 499–505, 2003.

PONZONI, F. J.; KUPLICH, T. M.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. Oficina de Textos, 2012.

ROSA, V. G. C. DA et al. Estimativa da produtividade de café com base em um modelo agrometeorológico-espectral. **Pesquisa Agropecuária Brasileira**, 2010. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2010001200020&lng=pt&tlng=pt>.

ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1973.

SETIYONO, T. D. et al. Spatial rice yield estimation based on MODIS and Sentinel-1 SAR data and ORYZA crop growth model. **Remote Sensing**, v. 10, n. 2, p. 1–20, 2018.

SILVA, W. F. et al. Simulated multipolarized MAPSAR images to distinguish agricultural

crops. **Scientia Agricola**, v. 69, n. 3, p. 201–209, 2012.

TORBICK, N. et al. Monitoring rice agriculture across myanmar using time series Sentinel-1 assisted by Landsat-8 and PALSAR-2. **Remote Sensing**, v. 9, n. 2, 2017.

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

VELOSO, A. et al. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. **Remote Sensing of Environment**, v. 199, p. 415–426, 2017.

WANG, N. et al. Evaluating coffee yield gaps and important biotic, abiotic, and management factors limiting coffee production in Uganda. **European Journal of Agronomy**, v. 63, p. 1–11, 2015.

ZHANG, Y. et al. Estimation of soil moisture index using multi-temporal Sentinel-1 images over Poyang Lake ungauged zone. **Remote Sensing**, v. 10, n. 1, p. 1–19, 2018.

CAPÍTULO 2

Estimativa da Produtividade do Cafeeiro em Pivô Central por Meio de Imagens Landsat-8 Considerando o Efeito de Sombreamento nas Entrelinhas de Plantio

1 INTRODUÇÃO

A cafeicultura apresenta grande impacto no âmbito geral da exportação brasileira e essa cultura tem grande influência na política econômica e cambial nacional, atuando diretamente nas relações exteriores, atraindo investimentos diversos desde seu cultivo, processamento e seguindo até sua comercialização. Dessa forma, compreende-se que o café é uma das culturas mais importantes do Brasil, pois a mesma impacta diretamente nas condições socioeconômicas do país (MIRANDA *et al.*, 2014).

Com a necessidade de proteção da produção cafeeira, diferentes técnicas de monitoramento vêm sendo aplicadas, visando proteger todo investimento energético, de tempo e dinheiro do cafeicultor. Para que se torne viável o monitoramento em larga escala, o uso de sensoriamento remoto tem crescido nos últimos anos (CHEMURA; MUTANGA; DUBE, 2017; TAUGOURDEAU *et al.*, 2014).

O uso do sensoriamento remoto orbital para o monitoramento do café tem se mostrado uma poderosa ferramenta para tomada de decisão do produtor. Contudo, muitos estudos retratam seu poder em detecção direta de características, apresentando um registro imediato considerando a data da imagem e a ocorrência do fenômeno em campo. Levando em conta essa condição, dependendo do problema detectado, pode-se inviabilizar o tempo de resposta do produtor para realizar os devidos tratamentos culturais preventivos e corretivos no campo (BERNARDES *et al.*, 2012).

O aproveitamento máximo das informações que as plataformas orbitais disponibilizam pode acarretar em diferença significativa na eficiência de identificação e caracterização de fenômenos presentes na área de estudo. O uso não apenas dos produtos primários, mas também de produtos derivados de processamento digital, como o caso de índices espectrais, pode elevar o nível de entendimento da matriz do agroecossistema, visto que muitos desses produtos consideram a interação entre as diferentes características intrínsecas dos alvos imageados (ARANTES *et al.*, 2017; GAO, 1996; JUSTICE *et al.*, 1998; ROUSE *et al.*, 1973; ZHANG *et al.*, 2014).

Compreender as características do alvo em estudo é um requisito essencial para a extração de suas informações de modo mais preciso e acurado possível. Verificar e

correlacionar suas diferentes condições apresentadas em campo, desde seu arranjo posicional, sua aparência relativa perante o sistema sensor utilizado e, até mesmo, suas características de desenvolvimento e resposta à estímulos, podem impactar na qualidade do estudo conduzido, caso não sejam levadas em conta (ATZBERGER *et al.*, 2013; BENTO; CAMARGO, 2015; CAMARGO; CAMARGO, 2001; DE CARVALHO *et al.*, 2010; ORTEGA-HUERTA *et al.*, 2012).

As lavouras de café sob sistema de irrigação por pivô central geralmente seguem a orientação circular de plantio, que pode influenciar na recepção da luz e da radiação solar, considerando as diferentes faces da planta do café. Esse arranjo posicional tende a promover divergências de iluminação na área, o que implica em assinaturas espectrais modificadas para o café, resultando em interpretações imprecisas sobre o comportamento e a situação da cultura (MARUJO *et al.*, 2017; MOREIRA *et al.* 2010).

A correta escolha não apenas do sistema sensor ideal, considerando suas diferentes características e resoluções espacial, espectral e temporal, mas, também, a definição de períodos críticos para o monitoramento intensificado, podem resultar num aumento da eficiência do acompanhamento da cultura, sem afetar significativamente nos custos associados à operação de monitoramento (MOREIRA; ADAMI; RUDORFF, 2004).

A possibilidade de determinar a produtividade de uma área cafeeira por meio de sensoriamento remoto, relacionando-a com um período específico do seu ciclo fenológico, permite um monitoramento mais prático e direto quanto a definição de momentos de manejo, em tempo hábil, no intuito de garantir a produtividade esperada.

Portanto, objetivou-se avaliar a correlação das respostas espectrais dos diferentes estádios fenológicos do café irrigado (*Coffea arabica* L.) com a produtividade média de frutos amostrados em campo por malha amostral.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

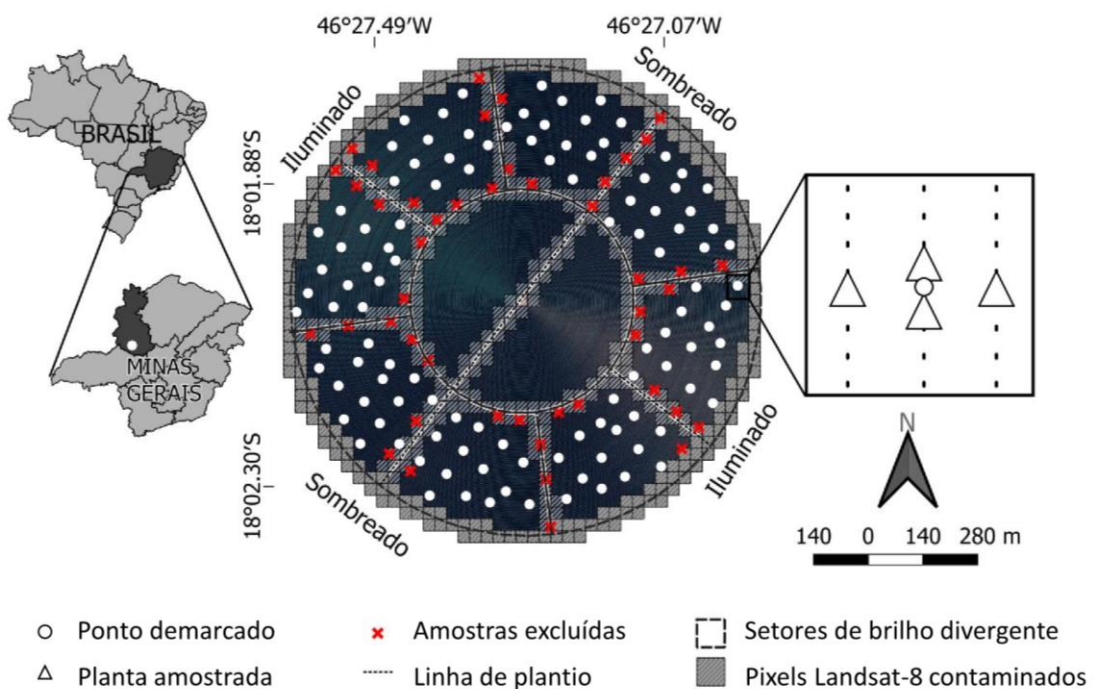
O estudo foi realizado em um pivô central localizado na fazenda Três Pontas no município de Presidente Olegário, estado de Minas Gerais, com coordenadas geográficas centrais em 18° 02' 2,93" de latitude sul e 46° 27' 16,80" de longitude oeste de *Greenwich*. Conforme a classificação climática apresentada por Köppen e Geiger (1936) e regionalizada por Alvares *et al.* (2013), o local de estudo está inserido na classe de Clima megatérmico tropical savânico (Aw), sendo o inverno a estação mais seca, apresentando o equivalente a menos de 4% da precipitação total anual.

A área de interesse apresenta 112 hectares com cultivo de café (*Coffea arabica* L.), da cultivar Catuaí IAC 144, implantada em dezembro de 2005. Após o ano agrícola 2013/2014, foi adotado o manejo de “safra zero”, realizando decote e esqueletamento da lavoura, resultando no aumento da colheita para o ano agrícola de 2015/2016, ao custo de não obter produção no ano agrícola de 2014/2015, conforme recomendações de Matiello *et al.* (2007) e Zerbinatti *et al.* (2014).

2.2 Obtenção de dados *in situ*

Os dados de campo nos quais este estudo se baseia, foram obtidos do acervo estruturado por Figueiredo *et al.* (2017). A obtenção de dados de campo foi realizada pela demarcação de pontos amostrais georreferenciados, definidos por malha amostral de dois pontos por hectare dentro da área do pivô estudado (FIGUEIREDO *et al.*, 2017). Considerando que a malha amostral não foi inicialmente planejada especificamente para o experimento com *Landsat-8*, para evitar que *pixels* contaminados pela presença de áreas não plantadas fossem incluídos, foi necessário identificar, selecionar e eliminar os pontos amostrais que se encontravam sobrepostos a *pixels* situados próximos às estradas, carreadores e divisas do pivô (FIGURA 2.1).

Figura 2.1 - Localização e esquema amostral utilizado no pivô central estudado.



Fonte: Do autor (2020).

Cada ponto amostral foi demarcado em campo utilizando receptor GNSS, nos quais os dados de produtividade foram coletados considerando quatro plantas de café ao redor do ponto demarcado na malha, sendo duas plantas na mesma linha do ponto georreferenciado e mais uma em cada linha adjacente (FIGUEIREDO *et al.*, 2017).

A quantificação da produtividade foi realizada com auxílio de baldes graduados, os quais foram preenchidos com os frutos dos cafeeiros, colhidos por derriça manual em panos posicionados nas entrelinhas, que permitiram varrer e incluir os frutos caídos durante o processo de colheita (FIGUEIREDO *et al.*, 2017). Esse tipo de amostragem permitiu obter a produtividade média pontual em unidades de litros por planta ($L.pl^{-1}$), a qual foi posteriormente convertida em sacas beneficiadas por hectare ($sc.ha^{-1}$) (Equação 1).

$$Prod_{(sc.ha^{-1})} = \frac{Prod_{(L.pl^{-1})} * N^{\circ} \text{ plantas por hectare}}{480} \quad (1)$$

Ao final de todo o processo de remoção de dados considerados incertos e organização do banco de dados geográfico, foram totalizados 114 pontos amostrais, separados em dois grupos de avaliação considerando sua divergência aparente de brilho, observada em diferentes talhões do pivô central, com 57 pontos cada, os quais foram submetidos a mesma bateria de análises estatísticas.

2.3 Obtenção de Dados Radiométricos de Plataforma Orbital

Utilizando a plataforma *Earth Explorer* de domínio da *United States Geological Survey* (USGS), foram obtidas imagens *Landsat-8*, durante um ano de observação da área de estudo, referente ao ano agrícola de 2015/2016, em que todas as imagens obtidas foram da mesma cena identificada pela órbita 220 e pelo ponto 73. Devido à condição de safra zero, determinou-se o início das observações em maio de 2015, que seguiu até junho de 2016, excluindo as datas em que se registrou presença de nuvens sobre a área estudada, verificada pelos valores de *Quality Assessment* (QA) dos *pixels* (USGS, 2018), obtendo-se um total de 14 datas de observação ao longo do período de estudo (TABELA 2.1).

O banco de dados foi suprido utilizando dados espectrais extraídos das bandas disponíveis dos sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS), com base na malha amostral regular que também foi utilizada para realizar a amostragem georreferenciada da produtividade média pontual em campo.

Para identificar a fase fenológica com maior potencial preditivo da produção cafeeira na área estudada, as datas registradas pelo sistema sensor foram classificadas pelos diferentes estádios fenológicos: gema dormente, chumbinho, expansão dos frutos, grão verde, verde cana, cereja, vegetativo pós-colheita (CAMARGO; CAMARGO, 2001; PEZZOPANE *et al.*, 2003), de acordo com o momento em o cafeeiro se encontrava durante da captura da cena.

Tabela 2.1 - Relação das datas selecionadas para o estudo, com base na qualidade de aquisição dos valores radiométricos para os *pixels* amostrados.

Data	Azimute solar no plano local (°)	Pior QA	Excluído
09/05/2015	40,75	480	X
25/05/2015	37,69	322	
10/06/2015	36,55	322	
26/06/2015	37,04	328	X
12/07/2015	38,81	322	
28/07/2015	41,61	322	
13/08/2015	45,32	322	
29/08/2015	50,04	480	X
14/09/2015	56,15	322	
30/09/2015	64,24	992	X
16/10/2015	74,74	322	
01/11/2015	86,81	480	X
17/11/2015	97,83	480	X
03/12/2015	105,05	992	X
19/12/2015	107,54	992	X
04/01/2016	105,74	480	X
20/01/2016	100,45	480	X
05/02/2016	92,46	322	
21/02/2016	82,55	480	X
08/03/2016	71,73	480	X
24/03/2016	61,17	992	X
09/04/2016	51,97	322	
25/04/2016	44,83	322	
11/05/2016	39,96	322	
27/05/2016	37,23	322	
12/06/2016	36,41	322	
28/06/2016	37,15	322	

Fonte: Do autor (2020).

As variáveis obtidas pelo *Landsat-8* incluem as reflectâncias das regiões visível, infravermelho próximo e de ondas curtas do espectro eletromagnético (sensor OLI), além de disponibilizar a informações sobre a temperatura de brilho (sensor TIRS), em escala decimal (TABELA 2.2). Antes de realizar a captura das informações pontuais pela malha, as imagens *Landsat-8* foram reprojetoados para coordenadas planas *Universal Transverse Mercator* (UTM),

zona 23 K, e corrigidas para reflectância da superfície seguindo o método *Land Surface Reflectance Code* (LaSRC), que se baseia na correção *Second Simulation of a Satellite Signal in the Solar Spectrum Vector* (6SV) (VERMOTE *et al.*, 2018).

Tabela 2.2 - Descrição das bandas espectrais obtidas pelo sistema sensor *Landsat-8 OLI/TIRS*.

	Sensor	Identificação	Descrição	Largura de banda (μm)
Bandas	OLI	B2	Azul	0,45 - 0,51
		B3	Verde	0,53 - 0,59
		B4	Vermelho	0,64 - 0,67
		B5	Infravermelho Próximo	0,85 - 0,88
		B6	Infravermelho de ondas curtas I	1,57 - 1,65
		B7	Infravermelho de ondas curtas II	2,11 - 2,29
		TIRS	B10	Infravermelho Termal I
B11	Infravermelho Termal II		11,5 - 12,51	
Resolução Espacial			30 metros/pixel (OLI)	
			100 metros/pixel (TIRS)	
Resolução Temporal			16 dias	

Fonte: USGS (2018).

Foram calculados índices espectrais como complemento ao banco de variáveis utilizadas (TABELA 2.3). Entre os diferentes índices apresentados pela literatura, foram utilizados o Índice de Vegetação Melhorado (EVI) (JUSTICE *et al.*, 1998), Índice de Vegetação Ajustado pelo Solo (SAVI) (HUETE, 1988) e os Índices pela Diferença Normalizada da Vegetação (NDVI) (ROUSE *et al.*, 1973), da Água (NDWI) (MCFEETERS, 1996) e de umidade (NDMI) (GAO, 1996).

Tabela 2.3 – Descrição dos índices espectrais obtidos a partir das bandas do *Landsat-8*.

Índice Espectral	Fórmula	Referência
EVI	$2,5 * \left(\frac{B5 - B4}{B5 + 6 * B4 - 7,5 * B2 + 1} \right)$	Justice <i>et al.</i> (1998)
NDVI	$\frac{B5 - B4}{B5 + B4}$	Rouse <i>et al.</i> (1973)
SAVI	$\left(\frac{B5 - B4}{B5 + B4 + 0,5} \right) * 1,5$	Huete (1988)
NDWI	$\frac{B3 - B5}{B3 + B5}$	Mcfeeters (1996)
NDMI	$\frac{B5 - B6}{B5 + B6}$	Gao (1996)

Fonte: Do autor (2020).

2.4 Análises Estatísticas

Os dados de refletância foram correlacionados com a produtividade de frutos nos pontos amostrais georreferenciados obtida em campo, no intuito de identificar a variação radiométrica ao longo do tempo e espaço, e se existe alguma correlação entre elas. Tal informação foi apurada por meio do Coeficiente de Correlação de Pearson (PEARSON, 1893) (Equação 2).

$$r = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{\sqrt{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \sqrt{n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2}}, \quad i = 1, 2, \dots, n \quad (2)$$

em que, r é expresso em valores entre -1 e 1. No caso deste estudo, x são os dados de refletância e índices espectrais, obtidos pelo *Landsat-8*, e y é a produtividade amostrada em campo.

A análise de correlação dos dados orbitais com a produtividade foi realizada em três grupos de amostras, sendo eles categorizados como “Área Total”, onde todos os pontos foram utilizados como população da análise, “Sombreados”, onde apenas os pontos nos setores mais escuros foram considerados, e “Iluminados”, onde apenas os pontos nos setores mais claros foram considerados.

Adicionalmente, foi adotada a Regressão Linear Múltipla, a fim de estabelecer um modelo que descreva a relação entre as variáveis estudadas (Equação 3).

$$Y = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_j x_{ij} + \varepsilon_i, \quad i = 1, 2, \dots, n \quad (3)$$

em que, Y foi a produtividade em $sc.ha^{-1}$, β , os coeficientes da regressão associados a cada x , que são os dados de reflectâncias e índices espectrais, obtidos pelo *Landsat-8*, e ε , a variável aleatória associada aos dados.

A regressão foi realizada a cada data de observação, para cada grupo de dados, utilizando todas as variáveis obtidas pelo *Landsat-8*, as quais, seguindo o Critério de Seleção M5 (DITTHAKIT; CHINNARASRI, 2012; QUINLAN, 1992), foram sendo eliminadas com base em sua significância para o modelo, baseado em coeficientes *t-stat* (STUDENT, 1908).

3 RESULTADOS E DISCUSSÃO

Observou-se que o pivô apresentou diferentes padrões de iluminação, os quais foram registrados em todas as bandas do sistema sensor e ocorreram devido ao plantio em orientação circular, acompanhando a forma do pivô central, sendo esta uma característica que pode dificultar a determinação da forma mais adequada de se avaliar as informações da área em estudo, como relatado nos trabalhos realizados por Moreira *et al.* (2010) e Oliveira *et al.* (2012).

Nos setores em que as linhas de plantio se apresentaram em orientação perpendicular ao ângulo azimutal de incidência dos raios solares, observou-se um padrão mais escuro na imagem, devido ao sombreamento das entrelinhas pelas próprias linhas de plantio e altura do cafeeiro. De forma contrária, nos setores em que as linhas de plantio estavam orientadas de forma paralela à incidência dos raios solares, foi observado um padrão mais claro e iluminado, pela incidência direta da luz nas entrelinhas da lavoura.

A divergência de iluminação observada se deve ao fato das informações espectrais do cafeeiro apresentarem valores mascarados ao serem registrados pelo sistema sensor orbital. Esse efeito mascara atuando no registro espectral ocorreu, principalmente, devido as condições de orientação dos setores da lavoura em relação ao sol e, adicionalmente, pela altura e geometria das plantas de café em relação ao terreno da área estudada, conforme observado também nos estudos realizados por Oliveira *et al.* (2012) e Turco e RIZZATTI (2006).

Observou-se que, ao utilizar todos os pontos indiscriminadamente, os coeficientes de correlação obtidos entre os dados espectrais com a produtividade observada foram baixos ($p \leq 5\%$). Separando os pontos e analisando-os considerando suas condições de iluminação, os coeficientes de correlação entre os dados espectrais e a produtividade foram maiores, o que pode ser explicado pela redução no número de amostras utilizadas para a análise (PEARSON, 1893) mas, também, pela separação das amostras em subgrupos com condições semelhantes de iluminação. Tal inferência é reforçada ao avaliar as correlações apresentadas pelas amostras presentes nos setores iluminados (TABELA 2.4).

Tabela 2.4 - Correlação significativa ($p \leq 5\%$) entre os dados espectrais do *Landsat-8* e a produtividade amostrada na área do pivô em junho/2016, considerando diferentes critérios de iluminação.

	Date	B2	B3	B4	B5	B6	B7	NDVI	EVI	SAVI	NDWI	NDMI
Área Total	25/05/15											
	10/06/15											
	12/07/15											
	28/07/15				0,24				0,25	0,27		
	13/08/15											
	14/09/15				0,24							
	16/10/15	0,22		0,25		0,18	0,21	-0,30	-0,20	-0,19	0,18	-0,22
	05/02/16											
	09/04/16	0,20	0,19	0,24		0,18	0,20	-0,26	-0,22	-0,22	0,27	-0,19
	25/04/16			0,17				-0,16	-0,23	-0,20		
	11/05/16								-0,17			
	27/05/16							-0,17	-0,37	-0,35	0,21	
	12/06/16			0,16				-0,21	-0,44	-0,43	0,24	-0,16
	28/06/16	0,17		0,19				-0,26	-0,46	-0,46	0,30	-0,19
Área Iluminada	25/05/15	0,28	0,36	0,35		0,30	0,30	-0,39	-0,46	-0,47	0,42	-0,35
	10/06/15		0,34	0,33	0,27	0,28	0,28	-0,33	-0,35	-0,32	0,35	-0,28
	12/07/15	0,48	0,42	0,33		0,27	0,27	-0,37	-0,33	-0,38	0,47	-0,32
	28/07/15	0,32	0,31		0,42	0,31	0,31					
	13/08/15	0,34	0,38	0,38		0,32	0,35	-0,42	-0,41	-0,37	0,44	-0,36
	14/09/15	0,28		0,38	0,31	0,34	0,36	-0,38				-0,33
	16/10/15	0,38	0,32	0,46		0,36	0,41	-0,56	-0,50	-0,49	0,46	-0,46
	05/02/16				0,27							
	09/04/16	0,54	0,51	0,56		0,46	0,49	-0,56	-0,30	-0,30	0,56	-0,45
	25/04/16	0,41	0,43	0,44	0,40	0,38	0,40	-0,44	-0,40	-0,36	0,41	-0,36
	11/05/16	0,36	0,38	0,38	0,37	0,32	0,32	-0,37	-0,27		0,36	-0,29
	27/05/16	0,31	0,33	0,36		0,28	0,29	-0,44	-0,56	-0,55	0,52	-0,38
	12/06/16	0,37	0,34	0,38		0,30	0,30	-0,46	-0,58	-0,58	0,51	-0,42
	28/06/16	0,38	0,37	0,41		0,32	0,34	-0,51	-0,57	-0,55	0,55	-0,44
Área Sombreada	25/05/15											
	10/06/15	-0,37	-0,31								-0,33	
	12/07/15											
	28/07/15		-0,29	-0,36	0,38			0,39	0,42	0,41	-0,41	0,34
	13/08/15											
	14/09/15				0,36							
	16/10/15											
	05/02/16											
	09/04/16											
	25/04/16											
	11/05/16											
	27/05/16											
	12/06/16			0,34	-0,43			-0,41	-0,46	-0,44	0,30	-0,28
	28/06/16	0,29		0,45	-0,44			-0,50	-0,51	-0,51	0,45	-0,31


Fonte: Do autor (2020).

Ao avaliar as reflectâncias e índices espectrais obtidos pelo *Landsat-8* ao longo do período de observação, verificou-se que as amostras presentes nos setores iluminados apresentaram maior número de variáveis, de datas de observação significativas e maior nível de correlação, se comparadas às amostras dos agrupadas como “sombreados” ou “área total”.

A diferença na relação dos dados agrupados pela divergência de brilho aparente foi observada devido à mistura espectral entre a cultura de interesse, informações do solo e sombreamento das entrelinhas, provocados principalmente pela orientação e posicionamento da lavoura, associada ao horário local de imageamento do sistema sensor orbital. Tais fatores combinados atuaram para o aumento da complexidade espectral do cafeeiro, dificultando seu monitoramento e caracterização adequada da sua situação em campo, assim como relatado nas abordagens de Oliveira *et al.* (2012) e Vieira *et al.* (2006).

Evidenciando ainda mais a interferência da iluminação na área do pivô, o gráfico de temperatura média ao longo do tempo (FIGURA 2.2), obtido utilizando os dados do sensor TIRS, permitiu observar que a temperatura média dos setores iluminados foi maior, se comparado à temperatura média dos setores sombreados.

Figura 2.2 – Temperaturas de brilho médias obtidas pela banda 10, Sensor TIRS, para as diferentes condições de iluminação, ao longo do período de observação.

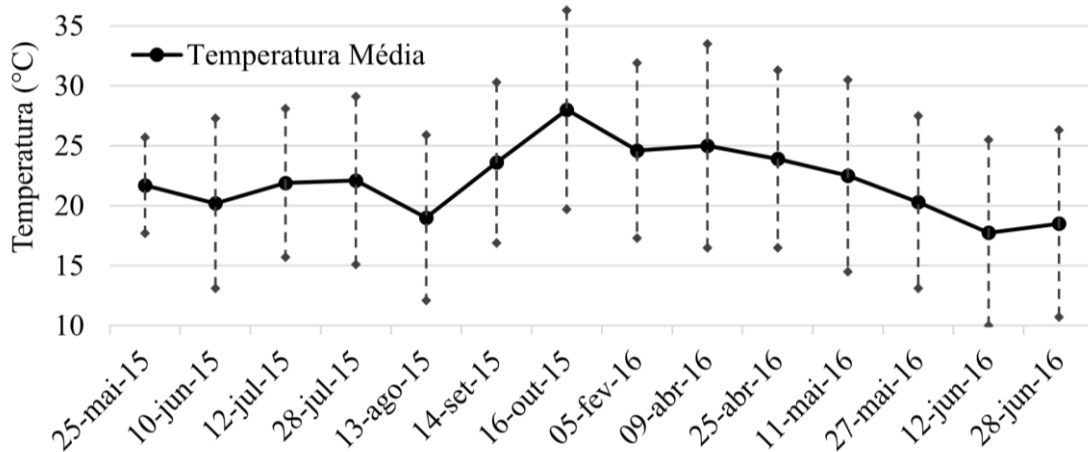


Fonte: Do autor (2020).

Analisando os dados de temperatura de brilho obtidos pelo *Landsat-8*, notou-se uma variação brusca da assinatura no mês de outubro. Checando os dados junto aos registros da estação meteorológica (FIGURA 2.3) do Instituto Nacional de Meteorologia (INMET), instalada no município de Carmo do Rio Claro - MG, confirmou-se que as temperaturas locais

coincidem com a assinatura obtida pelo *Landsat-8*, indicando também, considerável confiabilidade dos dados de temperatura obtidos pelo sistema sensor orbital para o local de estudo.

Figura 2.3 – Temperaturas mínimas, máximas e médias do município de Carmo do Rio Claro – MG obtidas pela estação meteorológica do INMET, para as datas correspondentes às imagens *Landsat-8* utilizadas no estudo.




Fonte: Do autor (2020).

Para as observações de outubro e fevereiro, a diferença de temperatura entre os setores foi menor, indicando uma influência atenuada da divergência de brilho na área. Esse efeito se deve pelo fato do posicionamento solar, no horário local de imageamento, se estabelecer próximo ao zênite do plano local, conferido pelo ângulo azimutal das datas em questão.

Confirmou-se que a temperatura média registrada pelo sensor TIRS foi em média três graus Célsius maior nas áreas iluminadas, em relação às áreas sombreadas, condizendo com levantamentos realizados em campo, consolidadas em estudos realizados para áreas cafeeiras sob condições divergentes de distribuição de iluminação natural por Butler (1977).

Baseando-se nos coeficientes de determinação (R^2) obtidos, o método de regressão linear múltipla permitiu identificar as datas mais adequadas para prever a produtividade do cafeeiro no campo (FIGURA 2.4).

Figura 2.4 – Coeficientes de determinação e erro médio das estimativas de produtividade baseadas nos dados espectrais obtidos pelo *Landsat-8*, ao longo do período de observação segmentado pelos estádios fenológicos do cafeeiro, demarcados como: (I) Gema dormente, (II) chumbinho, (III) expansão dos frutos, (IV) grão verde, (V) verde cana, (VI) cereja, (VII) vegetativo pós-colheita.



Fonte: Do autor (2020).

Apesar do sistema *Landsat-8* não ter registrado todas as fases fenológicas da lavoura, devido seu tempo de revisita de 16 dias, as imagens registradas e utilizadas nas análises se encontravam em fases fenológicas específicas, o que permitiu avaliar qual a fase fenológica apresentou maior potencial preditivo da produtividade obtida em campo, sendo elas a fase de gema dormente, para os setores sombreados, e chumbinho para os setores iluminados.

O resultado observado corroborou com os resultados obtidos por Nogueira *et al.* (2018), que identificou maior correlação da produção com os dados orbitais da plataforma *Landsat-8* obtidos entre os meses de julho a outubro.

Após ajuste dos modelos lineares, a produtividade foi estimada para os pontos utilizados na amostragem da produtividade observada em campo por Figueiredo *et al.* (2017), para cada

momento do período de observação. Esse processo permitiu verificar a variação do erro médio da previsão obtida por cada modelo, utilizando diferentes estádios do desenvolvimento da cultura em estudo.

Considerando a observação que apresentou o maior R^2 (0,545) e o menor erro médio de previsão (5,36 sc.ha⁻¹), temos que os dados obtidos pelo *Landsat-8*, na data 14/09/2015, apresentaram um modelo satisfatório de previsão de safra (Equação 4).

$$\text{Prod}_{(\text{sc.ha}^{-1})} = 41818,037 * (0,450B2 - 0,812B3 - 0,694B4 + B5 + 0,217\text{NDVI} - 0,208\text{EVI} + 0,147\text{NDWI} - 0,008\text{NDMI} - 0,433\text{SAVI} - 0,003) \quad (4)$$

Entretanto, ao utilizar a Equação 4, que foi obtida a partir da regressão dos dados dos setores iluminados, para estimar a produtividade em toda a área, foi observado que os dados contidos nos setores sombreados não se ajustaram adequadamente, acarretando em uma baixa relação entre a produtividade prevista e observada, quando aplicado em área total.

Por consequência, houve a necessidade de adequar o ajuste do modelo, dependendo da orientação da lavoura em relação ao ângulo azimutal do sol no momento que a imagem foi registrada pelo sensor. Dessa forma, também foi considerado o melhor modelo obtido para os dados inseridos nos setores sombreados do pivô. A data de observação que apresentou o maior R^2 (0,468) e menor erro médio (8,29 sc.ha⁻¹), associado para o setor sombreado, foi em 28/07/2015 (Equação 5).

$$\text{Prod}_{(\text{sc.ha}^{-1})} = 134991,687 * (-0,302B2 + 0,931B3 - B4 - 0,349B5 + 0,152B6 - 0,279\text{NDVI} + 0,113\text{EVI} - 0,176\text{NDWI} + 0,040\text{NDMI} + 0,067\text{SAVI} - 0,072) \quad (5)$$

A partir das Equações 4 e 5, obtidas para as diferentes situações de iluminação, observou-se que as bandas espectrais com maior influência nos modelos foram as bandas 5 e 4, respectivamente. Tais bandas apresentam forte relação com a atividade fotossintética das plantas e, normalmente, são relatadas em estudos relacionando o monitoramento do vigor e desenvolvimento vegetativo, utilizando índices espectrais a partir dessas bandas, como demonstrado nos estudos realizados por Rouse *et al.* (1973) Huete (1988) e Justice *et al.* (1998).


De modo contrário, para ambos os modelos, observou-se que o NDMI apresentou menor influência nos resultados dos modelos. Essa condição pode ser associada ao fato da área de estudo se restringir à uma lavoura sob manejo de irrigação por pivô central, cuja própria

uniformidade de molhamento propicia baixa diferenciação entre os pontos observados contidos da lavoura, sendo essa condição também registrada nos estudos de Pereira *et al.* (2018).

Aplicando as Equações 4 e 5, individualmente para cada setor, foi observado que o R^2 foi superior para cada condição de iluminação (FIGURA 2.5a e FIGURA 2.5b), se comparados à avaliação em área total (FIGURA 2.5c). Dessa forma, a aplicação de um ajuste de modelo específico para as diferentes condições de iluminação foi necessária para uma caracterização mais acurada da produtividade obtida em campo, assim como relatado por Marujo *et al.* (2017).

Estimando simultaneamente as produtividades, de forma condicional para os setores iluminados e sombreados (FIGURA 2.5d), utilizando os modelos e os dados das datas com maior coeficiente de determinação e menor erro, foi possível verificar um ajuste satisfatório dos modelos, com relação direta entre a produtividade observada em campo e a produtividade estimada por dados orbitais, mesmo utilizando todos os dados espectrais da área ao mesmo tempo.

Figura 2.5 - Dispersão entre a produtividade ($sc.ha^{-1}$) obtida em campo e a produtividade estimada, para as condições de pontos (a) iluminados, (b) sombreados, (c) todos os pontos sem separação e (d) todos os pontos em subconjuntos de iluminação.

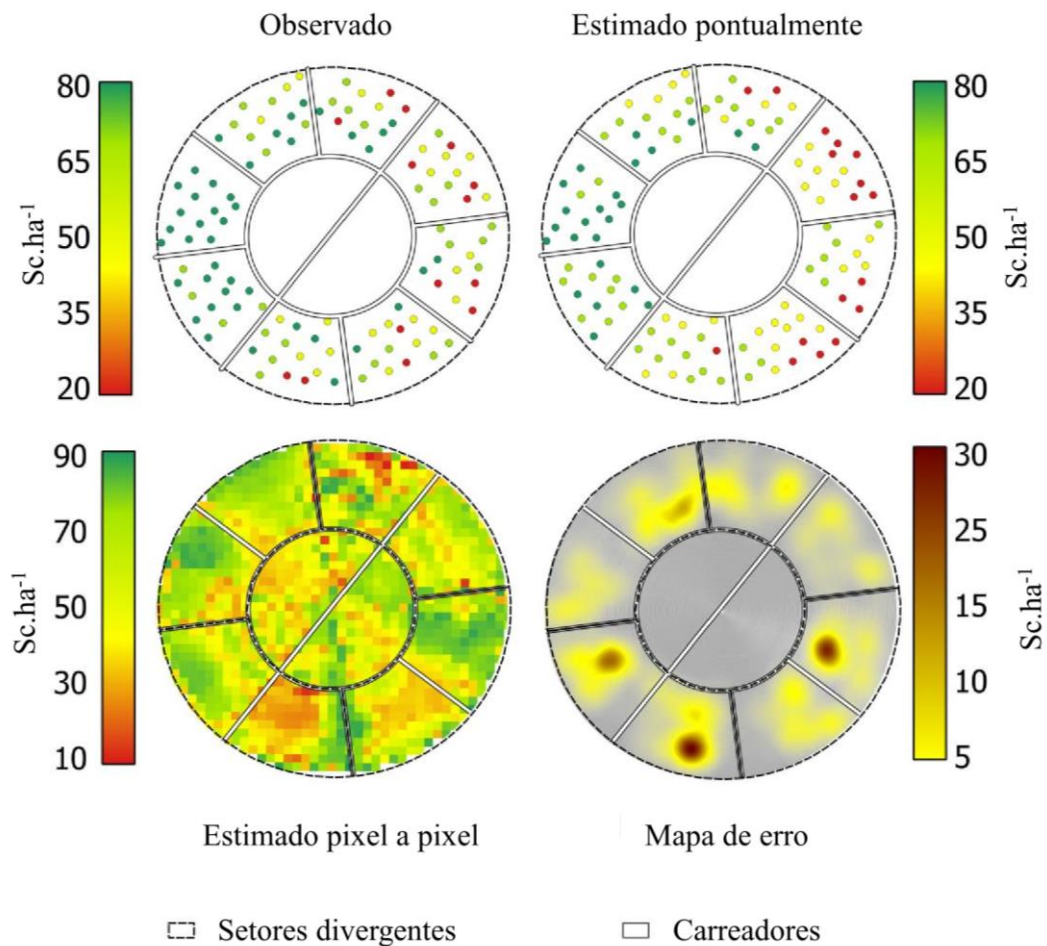


Fonte: Do autor (2020).

Com base no resultado obtido pela estimativa condicional, foram aplicadas as equações ajustadas pelo processo de regressão diretamente nas imagens provenientes do sistema sensor *Landsat-8*. A equação 4 foi aplicada para as imagens obtidas na data 14/09/2015, apenas nos setores iluminados, enquanto a equação 5 foi aplicada nas imagens obtidas na data 28/07/2015, apenas nos setores sombreados.

Por meio de uma operação matricial realizada diretamente nas imagens, e da aplicação dos melhores ajustes, *pixel a pixel*, condicionados às situações de iluminação, gerou um mapa de produtividade estimada para o ano de 2016, para toda a área estudada (FIGURA 2.6).

Figura 2.6 - Mapas da produtividade obtida para a área de estudo na fazenda Três Pontas, representando os dados amostrados, estimados e o erro associado.




Fonte: Do autor (2020).

Comparando diretamente a produtividade observada por Figueiredo *et al.* (2017) e a estimada nos mesmos pontos amostrais, notou-se média próxima e comportamento semelhante na variação dos dados obtidos. Entretanto, nos dados estimados, houve menor valor para a

mediana e amplitude, ou seja, a previsão apresentou menor variação, mas a produtividade foi subestimada (FIGURA 2.7).

Figura 2.7 - *Boxplot* das produtividades obtidas em campo e estimada para cafeeiro irrigado por pivô central estudado na fazenda Três Pontas.



Fonte: Do autor (2020).

Com base nos resultados obtidos das análises das bandas espectrais do sistema *Landsat-8*, observaram-se indícios de boa relação explicativa e preditiva em relação com os dados de campo de produtividade, desde que considerados diferentes subconjuntos de dados nas imagens separadamente.

Conforme relatos de Moreira *et al.* (2004), Dos Santos e Camargo (2006) e Miranda *et al.* (2014), o aumento da acurácia na previsão da produção cafeeira possibilita grande impacto socioeconômico, em escala local e global, devido sua constante demanda e alta influência nas flutuações do mercado financeiro.

O incremento do poder preditivo dos modelos contidos em sistemas de previsão de safra cafeeira possibilita a promoção de políticas e estratégias de produção e comercialização mais adequadas, contribuindo com a proteção e a valorização do agronegócio nacional.

4 CONCLUSÕES

Observou-se que o melhor período para realizar a estimativa da produção do café arábica, cultivar Catuaí IAC 144, sob sistema de irrigação de pivô central, se concentrou nos

meses de julho e setembro para a área estudada, considerando as condições de talhão sombreado e iluminado, respectivamente.

Avaliando as datas mais acuradas para realizar a estimativa da produção, concluiu-se que os estádios fenológicos com maior potencial preditivo foram os estádios de gema dormente, para o cafeeiro plantado em orientação perpendicular à incidência solar, e estádio de chumbinho para o cafeeiro plantado em orientação paralela à incidência solar.

O estande da lavoura, associado ao padrão circular das linhas de plantio, promoveu diferença na análise de correlação dos dados orbitais, assim como na regressão linear múltipla com base nos dados de produtividade obtidos em campo.

Apesar da lavoura receber iluminação com distribuição regular ao longo do dia, o registro realizado pelo sistema sensor de alta resolução num dado momento específico, com revisitas regulares no mesmo horário e local, podem acarretar em análises e conclusões equivocadas quanto à estimativa da produção em área total, caso não sejam consideradas as divergências de brilho presentes na cena da área estudada.

Foi possível realizar estimativas com base nos dados obtidos ainda no início do ciclo do cafeeiro, com erro relativamente baixo, apresentando grande potencial para o seu uso em levantamentos e estudos mais aprofundados sobre a estimativa de safra.

REFERÊNCIAS

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 1 dez. 2013.

ARANTES, T. B. et al. Effectiveness of BFAST algorithm to characterize time series of dense forest, agriculture and pasture in the amazon region. **Theoretical and applied engineering**, v. 1, p. 10–19, 2017.

ATZBERGER, C. et al. Phenological metrics derived over the European continent from NDVI3g data and MODIS time series. **Remote Sensing**, v. 6, n. 1, p. 257–284, 2013.

BERNARDES, T. et al. Monitoring biennial bearing effect on coffee yield using MODIS remote sensing imagery. **International Geoscience and Remote Sensing Symposium (IGARSS)**, v. 5, p. 3760–3763, 2012.

MARUJO, R. DE F. B. et al. Coffee crop detection by automatic classification of illumination. p. 17–28, 2017.

BUTLER, D. R. Coffee leaf temperatures in a tropical environment. **Acta Botanica Neerlandica**, v. 26, n. 2, p. 129–140, 1977.

CAMARGO, Â. P. DE; CAMARGO, M. B. P. DE. Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil. **Bragantia**, v. 60, n. 1, p. 65–68, 2001.

CHEMURA, A.; MUTANGA, O.; DUBE, T. Integrating age in the detection and mapping of incongruous patches in coffee (*Coffea arabica*) plantations using multi-temporal Landsat 8 NDVI anomalies. **International Journal of Applied Earth Observation and Geoinformation**, v. 57, p. 1–13, 2017.

DE CARVALHO, A. M. et al. Correlação entre crescimento e produtividade de cultivares de café em diferentes regiões de Minas Gerais, Brasil. **Pesquisa Agropecuaria Brasileira**, v. 45, n. 3, p. 269–275, 2010.

DITTHAKIT, P.; CHINNARASRI, C. Estimation of pan coefficient using M5 model tree. **American Journal of Environmental Sciences**, v. 8, n. 2, p. 95–103, 2012.

DOS SANTOS, M. A.; DE CAMARGO, M. B. P. Agrometeorological model parameterization for coffee yield estimation in São Paulo. **Bragantia**, v. 65, n. 1, p. 173–183, 2006.

FIGUEIREDO, V. C. et al. Análise da variabilidade espacial da força de desprendimento dos frutos do cafeeiro sob pivô central. **Coffee Science**, v. 12, n. 2, p. 84–92, 2017.

GAO, B. C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, 1996.

HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.

JUSTICE, C. O. et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): Land remote sensing for global change research. **Ieee Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1228–1249, 1998.

KÖPPEN, G. W.; GEIGER, M. R. Handbuch der klimatologie. **Bulletin of the American Geographical Society**, v. 43, n. 12, p. 935, 1936.

MATIELO, J. B.; GARCIA, A. W. R.; ALMEIDA, S. R. DE. A poda em cafezais. **Revista Brasileira de Tecnologia Cafeeira: Coffea**, v. 4, n. 11, p. 44, 2007.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v. 17, n. 7, p. 1425–1432, 1996.

MIRANDA, J. M. et al. Modelo matemático para previsão da produtividade do cafeeiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 4, p. 353–361, 2014.

MOREIRA, M. A.; ADAMI, M.; RUDORFF, B. F. T. Análise espectral e temporal da cultura do café em imagens Landsat. **Pesquisa Agropecuaria Brasileira**, v. 39, n. 3, p. 223–231, 2004.

MOREIRA, M. A. et al. Geotecnologias para mapear lavouras de café nos estados de minas gerais e são paulo. **Engenharia Agrícola**, v. 30, n. 6, p. 1123–1135, 2010.

OLIVEIRA, K. M. G. et al. Modelagem para a estimativa da orientação de linhas de plantio de cafeeiros. **Engenharia Agrícola**, p. 57–77, 2012.

ORTEGA-HUERTA, M. A. et al. Mapping coffee plantations with land sat imagery: An example from El Salvador. **International Journal of Remote Sensing**, v. 33, n. 1, p. 220–242, 2012.

PEARSON, K. Contributions to the mathematical theory of evolution. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 185, p. 71–110, 1893.

PEREIRA, L. E. et al. Análise Comparativa entre métodos de Índice de Água por Diferença Normalizada (NDWI) em área úmida continental. **Anuário do Instituto de Geociências**, v. 41, n. 2, p. 654–662, 2018.

PEZZOPANE, J. R. M. et al. Escala para avaliação de estádios fenológicos do cafeeiro arábica. **Bragantia**, v. 62, n. 3, p. 499–505, 2003.

QUINLAN, J. R. Learning with continuous classes. **Proceedings AI'92, 5th Australian Conference on Artificial Intelligence**. World Scientific, v. 92, p. 343–348, 1992.

ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1973.

STUDENT. The Probable Error of a Mean. **Biometrika**, v. 6, n. 1, p. 1, 1908.

TAUGOURDEAU, S. et al. Leaf area index as an indicator of ecosystem services and management practices: An application for coffee agroforestry. **Agriculture, Ecosystems and Environment**, v. 192, p. 19–37, 2014.

TURCO, J. E. P.; RIZZATTI, G. S. Avaliação de modelo matemático para estimar a radiação solar incidente sobre superfícies com diferentes exposições e declividades. **Engenharia Agrícola**, v. 26, n. 1, p. 257–267, 2006.

USGS, U. S. G. S. **Landsat 8 Surface Reflectance Code (Lasrc)**. n. 12, p. 40, 2018.

VERMOTE, E. et al. LASRC (Land Surface Reflectance Code): Overview, application and validation using MODIS, VIIRS, LANDSAT and Sentinel 2 data's. **International Geoscience and Remote Sensing Symposium (IGARSS)**, v. 2018- July, p. 8173–8176, 2018.

VIEIRA, T. G. C. et al. Crop parameters and spectral responde of coffee (Coffea arabica L.) Areas Within the State of Minas Gerais, Brazil. **Coffee Science**, v. 1, n. 2, p. 111–118, 2006.

ZERBINATTI, O. E. et al. Briquetagem de resíduos de cafeeiro conduzido no sistema safra zero. **Semina: Ciências Agrárias**, v. 35, n. 3, p. 1143–1152, 2014.

ZHANG, Z. et al. MODIS NDVI time series clustering under dynamic time warping.
International Journal of Wavelets, Multiresolution and Information Processing, v. 12, n.
05, p. 1461011, 2014.

CAPÍTULO 3

Obtenção de Assinatura de EVI para Lavouras Cafeeiras sob Diferentes Sistemas de Irrigação por Meio de Análise de Séries Temporais

1 INTRODUÇÃO

O café é uma das principais *commodities* que movimentam a economia mundial, sendo cultivado em diversos países como principal produção primária. Em razão da sua característica perene, o seu cultivo representa um investimento em longo prazo e sua relativa sensibilidade a características edafoclimáticas podem apresentar um risco para a viabilidade da sua produção (CHEMURA; MUTANGA; DUBE, 2017a; MIRANDA *et al.*, 2014).

Para garantir a importância socioeconômica e assegurar o investimento aplicado na cafeicultura para implantação, cultivo e produção de lavouras nas regiões cafeeiras, o monitoramento das plantas deve ser realizado para conduzir tomadas de decisões quanto à intervenções preventivas ou corretivas em tempo hábil (CHEMURA; MUTANGA; DUBE, 2017b; TAUGOURDEAU *et al.*, 2014).

Uma forma direta e dinâmica de realizar o monitoramento do desenvolvimento de uma cultura agrícola é trabalhar com suas assinaturas espectrais, que respondem de formas distintas para diferentes características presentes na lavoura, como, por exemplo, nas diferentes fases fenológicas ou nas ocorrências de pragas e doenças (BERNARDES *et al.*, 2012).

Utilizando técnicas de sensoriamento remoto por meio de sensores orbitais, é possível obter dados de respostas espectrais de alvos terrestres para acompanhar as mudanças na matriz da paisagem monitorada. Contudo, a eficiência do monitoramento depende das características dos sensores utilizados no imageamento, como as resoluções espectrais, espaciais e temporais de cada plataforma orbital (ATZBERGER *et al.*, 2013).

Entre os diferentes satélites disponíveis para adquirir dados de sensoriamento remoto, o Espectroradiômetro Imageador de Resolução Moderada (MODIS) tem sido utilizado no monitoramento da cafeicultura. O MODIS apresenta resolução espacial moderada de 250 metros/pixel, alta resolução espectral, registrando informações em vários comprimentos da onda eletromagnética segmentada em 36 bandas, alta resolução temporal com revisitas diárias ou cenas compostas de 16 dias para cada ponto imageado e, além dessas características, o acesso ao seu acervo de imagens é gratuito, contribuindo para a viabilidade econômica dos estudos realizados com essa plataforma (LATORRE *et al.*, 2003; ZHANG *et al.*, 2014).

Um dos mais populares produtos disponibilizados pelo MODIS para o monitoramento de biomas e lavouras é o Índice de Vegetação Melhorado (EVI). Esse índice indica a intensidade do vigor vegetativo a partir da variação espectral das plantas em comprimentos de onda específicos da radiação eletromagnética. O EVI foi baseado no Índice de vegetação da Diferença Normalizada (NDVI), proposto por Rouse *et al.* (1973), porém com um melhor ajuste em sua equação que evita obter valores numa região de saturação do modelo (ARANTES *et al.*, 2017; PONZONI; KUPLICH; SHIMABUKURO, 2012; JUSTICE *et al.*, 1998; ROUSE *et al.*, 1973).

A utilização de médias mensais dos índices de vegetação para a caracterização, classificação e monitoramento de culturas agrícolas, tem sido satisfatório para acompanhar o desenvolvimento de culturas agrícolas. Porém, ao realizar uma abordagem temporal para caracterizar e monitorar todo o ciclo fenológico do cafeeiro, a forma como a área é manejada ao longo do tempo pode alterar, mesmo que sutilmente, o padrão espectral esperado da cultura, acarretando em incertezas durante o processo de caracterização da assinatura espectral e de classificação da lavoura observada (ORTEGA-HUERTA *et al.*, 2012).

Determinar um comportamento normal esperado para a assinatura espectral da lavoura cafeeira pode colaborar na detecção do surgimento de pragas e doenças, que põem em risco a produção estimada. Uma forma de obter o comportamento padrão de uma lavoura agrícola é a partir de análise de séries temporais, que objetiva, principalmente, descrever os mecanismos geradores da série, possibilitando encontrar periodicidades em longo prazo, colaborando com tomada de decisões a partir de comportamentos previstos a curto ou longo prazo (MORETTIN; DE CASTRO TOLOI, 2006).

Uma das técnicas mais utilizadas para estudos conduzidos em séries temporais é o uso de modelos Auto-regressivos Integrados de Médias Móveis Sazonal (SARIMA) (BOX; JENKINS, 1970; BOX; PIERCE, 1970), que consideram o valor de uma variável num determinado instante, como uma função de sua autocorrelação defasada temporalmente (HARRIS; ABDUAL-AZIZ; AVUGLAH, 2012; MORETTIN; DE CASTRO TOLOI, 2006).

Aplicar tais técnicas de modelagem em séries temporais de índices de vegetação de cafeeiros pode ser um método para reduzir a confusão gerada por algoritmos classificadores de culturas agrícolas, além de auxiliar previamente em protocolos de tomada de decisão para manejo preventivo ou corretivo (TAUGOURDEAU *et al.*, 2014).

Partindo-se da hipótese de que obter a assinatura espectro-temporal normal de uma lavoura cafeeira, com base em seu histórico espectral, pode colaborar com identificação da ocorrência de pragas e doenças a partir de divergências entre comportamento previsto e


observado, o presente estudo objetivou caracterizar a dinâmica espectral do desenvolvimento vegetativo de lavouras cafeeiras irrigadas por diferentes sistemas de irrigação, ao longo do tempo, verificando a distinção das assinaturas espectrais de EVI sob diferentes condições de manejo hídrico do cultivo, avaliando a acurácia da previsão obtida a partir da modelagem temporal.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

O estudo foi conduzido no município de Carmo do Rio Claro, localizado na região sul/sudoeste do estado de Minas Gerais, Brasil. O local de estudo está inserido na classe de Clima mesotérmico subtropical úmido (Cwa), apresentando inverno seco e verão úmido, conforme classificação climática apresentada por Köppen e Geiger (1936) e Alvares *et al.* (2013). Foram selecionadas três lavouras de café arábica (*Coffea arabica* L.), da cultivar Acaia 474/19, submetidas as diferentes condições de irrigação, de uma mesma propriedade com coordenadas geográficas centrais em 21° 00' 10" latitude sul e 46° 02' 20" longitude oeste (FIGURA 3.1). As lavouras com sistema de irrigação autopropelido, gotejamento e sequeiro foram implantadas nos anos de 2005, 2007, 2006, respectivamente.

Figura 3.1 - Localização dos talhões estudados no município de Carmo do Rio Claro, sob manejo da irrigação por autopropelido (a), gotejamento (b) e sequeiro (c).



Fonte: Do autor (2020).

2.2 Dados Radiométricos de Plataforma Orbital

Para avaliar o desenvolvimento das lavouras cafeeiras ao longo do tempo, foram utilizados dados orbitais do sensor MODIS, satélite Terra, produto MOD13Q1 versão 6, obtidos por meio do Aplicativo para Extração e Exploração de Amostras Prontas para Análise (*AppEEARS*), que é um aplicativo em interface web sob domínio da *United States Geological Survey* (USGS). Entre os diferentes produtos disponibilizados pelo sensor MODIS, o produto MOD13Q1 versão 6, registrou o EVI *pixel a pixel* da área de estudo, com resolução espacial de 250 metros/*pixel*.

O EVI apresenta valores compreendidos entre -1 e 1, onde quanto maior o valor, maior o vigor vegetativo do local estudado. Proposto por Justice *et al.* (1998), o EVI foi obtido pela Equação 6:

$$EVI = G \frac{NIR - RED}{L + NIR + C1 * RED - C2 * BLUE} \quad , \quad (6)$$

em que, NIR é a refletância da superfície registrada na faixa do infravermelho próximo, RED é a refletância registrada na faixa do vermelho, BLUE é a refletância registrada na faixa do azul, G é o fator de ganho, L é o fator de ajuste do solo, C1 e C2 são coeficientes de ajuste de efeitos aerossóis na atmosfera. Seguindo recomendações, por padrão, utiliza-se G = 2,5, L = 1, C1 = 6 e C2 = 7,5 (JUSTICE *et al.*, 1998).

O período de aquisição de dados da série temporal teve seu início definido a partir de dois anos do ano de implementação de cada sistema de irrigação, seguindo por um período de oito anos de acompanhamento, com intervalos regulares de 16 dias entre as observações, totalizando 182 observações para cada lavoura estudada. Os primeiros sete anos foram utilizados para o ajuste dos modelos temporais, enquanto o último ano foi utilizado para verificar a acurácia do ajuste.

2.3 Análise de Séries Temporais

As observações foram agrupadas em médias mensais, que permitiram uma abordagem temporal com defasagens constantes. Para que o modelo SARIMA pudesse descrever satisfatoriamente a série temporal ao final do ajuste, foi necessário verificar que a mesma não apresentava comportamento explosivo (BOX; JENKINS, 1970), exibindo um modelo aditivo de suas componentes (Equação 7).

$$Y_t = T_t + S_t + e_t, \quad (7)$$

em que, Y_t é a série temporal, T_t é a componente de tendência, S_t é a componente sazonal e e_t é o ruído associado aos dados.

A estacionariedade da série foi verificada, preliminarmente, por meio do próprio gráfico da série temporal. A partir dos gráficos de dispersão da amplitude pela média, periodograma e do ajuste de mínimos quadrados ordinários (MQO), foi possível verificar a necessidade de transformação dos dados e presença das componentes sazonais e de tendência, respectivamente (HAMILTON, 1992).

A função de autocorrelação (FAC) evidencia a correlação existente entre as observações da série temporal, considerando a defasagem de tempo determinada. O correlograma gerado pela FAC ressalta a que alcance temporal as observações ainda estão significativamente correlacionadas, indicando a ordem inicial a ser utilizada para o ajuste dos modelos SARIMA (BOX; JENKINS, 1970; HARRIS; ABDUAL-AZIZ; AVUGLAH, 2012; MORETTIN; DE CASTRO TOLOI, 2006).

A partir das informações obtidas pela FAC, modelos Auto-Regressivos Integrados de Médias Móveis Sazonal (SARIMA) (Equação 8) foram ajustados para cada lavoura estudada, baseando-se na estrutura apresentada pelas próprias séries de EVI.

$$\nabla^D \Delta^d Z_t = \varphi_1 B_1 + \varphi_2 B_2 + \dots + \varphi_P B_P - \theta_1 B_1 - \theta_2 B_2 - \dots - \theta_q B_q + \Phi_1 B_1^D + \Phi_2 B_2^D + \dots + \Phi_P B_P^D - \Theta_1 B_1^D - \Theta_2 B_2^D - \dots - \Theta_Q B_Q^D + a_t, \quad (8)$$

em que, Z_t é a série temporal de EVI, D é a ordem de diferenciação sazonal da série para torná-la estacionária, d é a ordem de diferenciação não-sazonal da série para torná-la estacionária, p é a ordem do modelo auto-regressivo não-sazonal, P é a ordem do modelo auto-regressivo sazonal, q é a ordem do modelo de médias móveis não-sazonal, Q é a ordem do modelo de médias móveis sazonal, ∇ é a diferença sazonal de ordem D , Δ é a diferença não-sazonal de ordem d , φ é o parâmetro referente ao ajuste auto-regressivo não-sazonal, θ é o parâmetro referente ao ajuste de médias móveis não-sazonal, Φ é o parâmetro referente ao ajuste auto-regressivo sazonal, Θ é o parâmetro referente ao ajuste de médias móveis sazonal, a_t é o erro ou ruído relacionado ao ajuste, B_n é o operador de translado para o passado com *lag* n , denotado

por $B_n = Z_{t-n}$ (BOX; JENKINS, 1970). De modo geral, os modelos SARIMA podem ser escritos como SARIMA (p, d, q) (P, D, Q).

Os diferentes modelos obtidos para cada sistema de irrigação foram ranqueados de acordo com seu nível de ajuste, verificado pelos Critérios de Informação de Akaike (AIC), Bayesiano de Schwarz (BIC) e Hannan-Quinn (HQ) (AKAIKE, 1979; FINDLEY, 1991; SIN; WHITE, 1996).

A partir dos modelos SARIMA ajustados foi realizado o teste de autocorrelação residual de Box & Pierce (BOX; PIERCE, 1970), para verificar se os modelos foram bem ajustados e se os erros residuais associados não apresentam mais correlação entre si, caracterizando um ruído branco (RB).

A análise de autocorrelação do quadrado dos resíduos dos modelos ajustados foi realizada para verificar a necessidade de ajustar novos modelos para possível volatilidade presente na série. A volatilidade de séries temporais diz respeito ao comportamento heterocedástico da série em relação ao tempo. A presença dessa característica pode ser verificada elevando os resíduos do modelo ajustado ao quadrado e verificando a correlação significativa das defasagens ao longo do tempo (BOX; JENKINS, 1970; BOX; PIERCE, 1970; MORETTIN; DE CASTRO TOLOI, 2006)

Para quantificar o erro associado à previsão do EVI em cada série estudada foram utilizadas as medidas de erro quadrado médio de previsão (Equação 9) e erro percentual absoluto médio (Equação 10).

$$MSPE = E[(Y_t - \hat{Y}_t)^2], \quad (9)$$

$$MAPE = \frac{100}{n} \sum_{t=n+1}^{n+h} \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|, \quad (10)$$


em que, MSPE é o Erro Quadrado Médio de Previsão, adimensional por se tratar do EVI, MAPE é o Erro Percentual Absoluto Médio, expresso em porcentagem (%), Y_t é o valor observado e \hat{Y}_t é o valor obtido pela previsão (PINDYCK; RUBINFELD, 1991).

3 RESULTADOS E DISCUSSÃO

Observando os gráficos das séries temporais (FIGURA 3.2), verificou-se que em todas as lavouras estudadas houve sazonalidade aparente pela oscilação dos dados da série de EVI. Contudo, para o caso do sistema de gotejamento, diferente dos outros sistemas, notou-se uma

possível tendência nos dados, indicada pelo comportamento crescente da série ao longo do tempo.

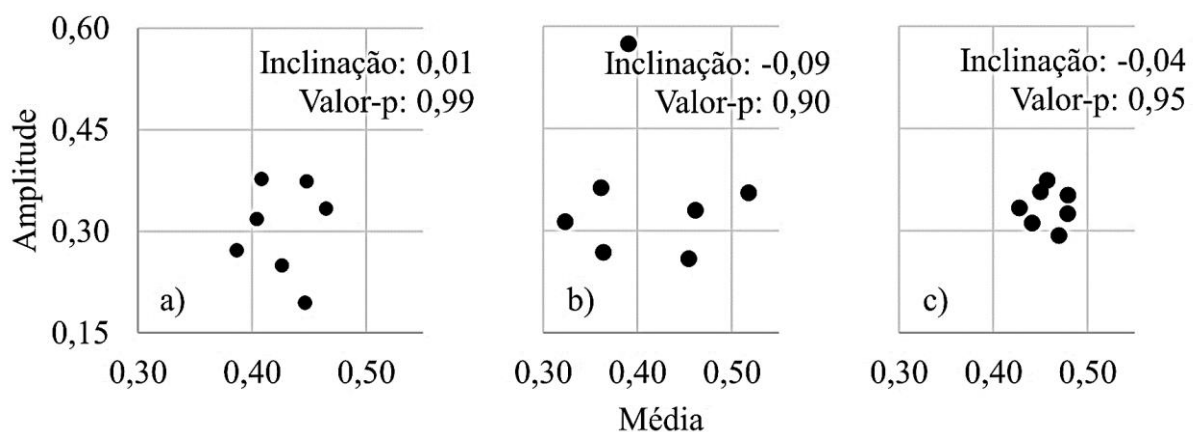
Figura 3.2 - Série temporal dos sistemas de manejo de irrigação autopropelido (a), gotejamento (b) e sequeiro (c) em Carmo do Rio Claro, MG.



Fonte: Do autor (2019).

Analisando os gráficos de amplitude pela média (FIGURA 3.3), verificou-se que a série não apresenta necessidade de transformação para estabilizar a variância de suas observações, indicando assim, que a série segue um modelo aditivo, tal qual apresentado por Morettin & Tolo (2006).

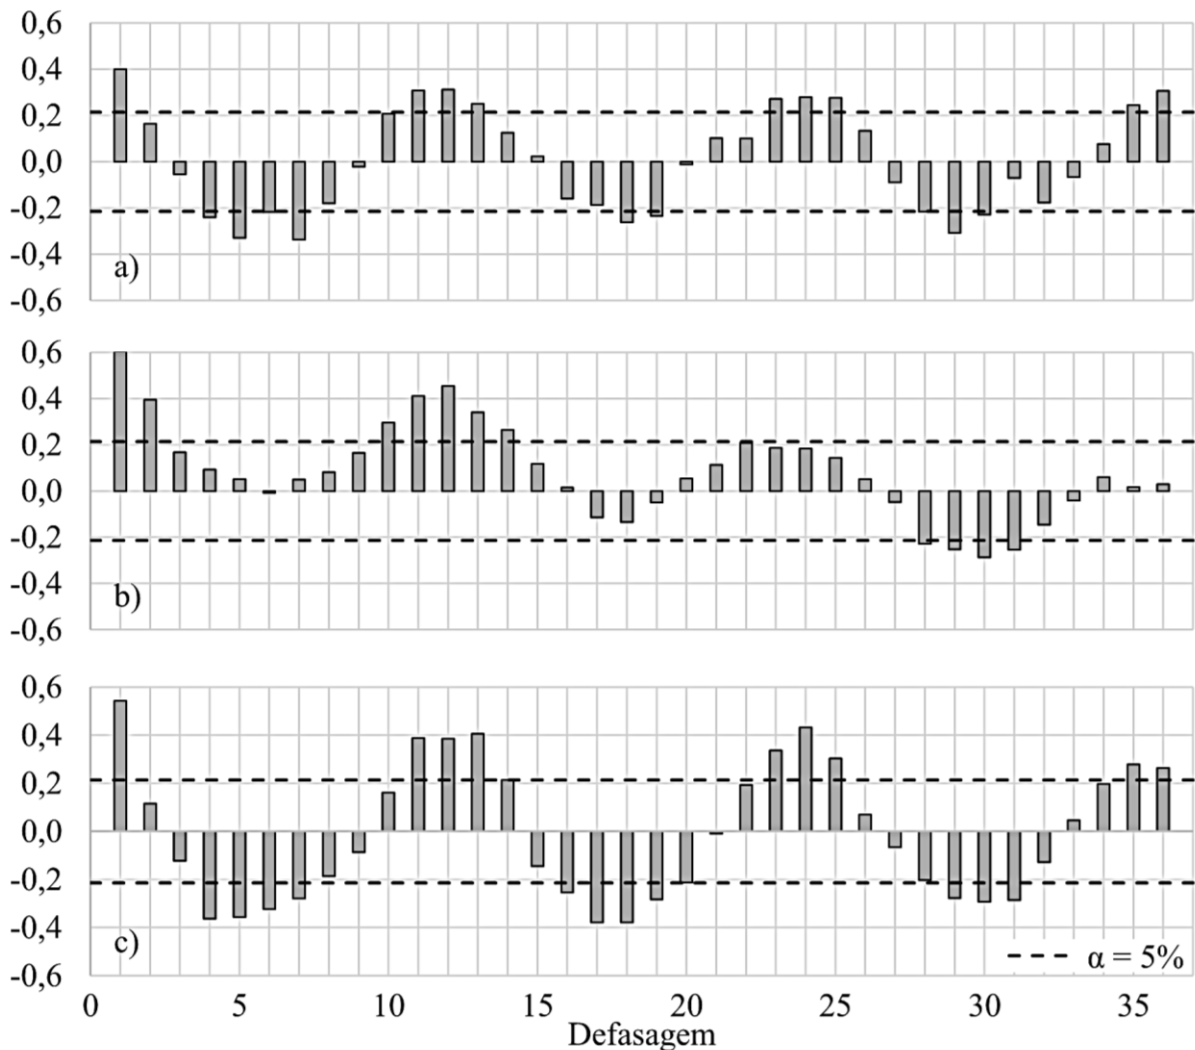
Figura 3.3 - Dispersão da amplitude pela média para os dados dos sistemas de manejo de irrigação autopropelido (a), gotejamento (b) e sequeiro (c) em Carmo do Rio Claro, MG.



Fonte: Do autor (2020).

Com base nos gráficos da função de autocorrelação dos três sistemas de manejo de irrigação, evidenciou-se a presença de sazonalidade pela ondulação característica dos valores, porém não exibiu tendência aparente em nenhum dos sistemas (FIGURA 3.4).

Figura 3.4 - Função de autocorrelação das séries de dados dos sistemas de manejo de irrigação autopropelido (a), gotejamento (b) e sequeiro (c) em Carmo do Rio Claro, MG.



Fonte: Do autor (2020).

A tendência apontada pelo gráfico da série do sistema de gotejamento pode ter sido mascarada pelo efeito de sua sazonalidade, que foi indicada em ambos os métodos visuais aplicados.

Avaliando os resultados obtidos pelo MQO (TABELA 3.1) e considerando o nível de significância $\alpha = 5\%$, o sistema de gotejamento foi o único sistema que teve a presença de sua componente de tendência confirmada, a qual foi considerada para o ajuste de modelo, indicando a necessidade de realizar diferenciação não-sazonal para torná-la estacionária.


Tabela 3.1 - Verificação da presença de tendência por meio do ajuste de Mínimos Quadrados Ordinários para os dados dos diferentes sistemas de manejo de irrigação em Carmo do Rio Claro, MG.

	Coeficiente	Desvio Padrão	Valor-p
Autopropelido	0,001	0,001	0,093 *
Gotejamento	0,002	0,001	0,001 ***
Sequeiro	-0,001	0,001	0,674 n.s

Fonte: Do autor (2020).

Avaliando os periodogramas, confirmou-se a presença da componente sazonal em todos os sistemas avaliados (FIGURA 3.5), indicando a necessidade de realizar diferenciação sazonal para torná-la estacionária. O registro de um máximo da densidade espectral no período de número 12, foi condizente com o fato dos dados terem sido preparados de forma mensal, ressaltando o ciclo anual da cultura agrícola.

Figura 3.5 - Periodogramas para os dados dos sistemas de manejo de irrigação autopropelido (a), gotejamento (b) e sequeiro (c) em Carmo do Rio Claro, MG.



Fonte: Do autor (2020).

Verificou-se que todos os sistemas avaliados apresentaram observações correlacionadas no tempo, componente sazonal e, para o caso do sistema de gotejamento, presença da componente de tendência. Assim, o ajuste de modelos ARIMA sazonais (SARIMA) foi necessário para que cada talhão fosse caracterizado de forma adequada.

Tendo como base os valores significativos da função de autocorrelação e autocorrelação parcial, foram ajustados modelos SARIMA para cada sistema estudado (TABELA 3.2).

Tabela 3.2 - Resumo dos parâmetros dos melhores modelos SARIMA ajustados para os dados dos diferentes sistemas de manejo de irrigação em Carmo do Rio Claro, MG.

	Modelo	ϕ_1	Θ_1	θ_1	AIC	BIC	HQ	Cte
Autopropelido	SARIMA (0,0,0) (0,1,1) ₁₂	-	-1,00	-	-133,97	-127,14	-131,25	-
	d.p.		(0,17)					
Gotejamento	SARIMA (0,1,1) (0,1,1) ₁₂	-	-0,59	-0,75	-126,69	-119,9	-123,99	-
	d.p.		(0,20)	(0,12)				
Sequeiro	SARIMA (0,0,1) (1,1,1) ₁₂	-0,50	-1,00	0,89	-154,38	-145,27	-150,75	-
	d.p.	(0,14)	(0,34)	(0,09)				

Fonte: Do autor (2020).


Com base nos melhores modelos ajustados para cada lavoura, indicados pelos menores valores de AIC, BIC e HQ, os resultados do teste de autocorrelação residual de Box & Pierce foram:

- Sistema autopropelido: $Q(36) = 37,79 < \chi^2_{35, 0,05} = 49,80$;
- Sistema de gotejamento: $Q(36) = 31,49 < \chi^2_{34, 0,05} = 48,60$;
- Sistema de sequeiro: $Q(36) = 30,28 < \chi^2_{33, 0,05} = 47,40$.

Todos os modelos atingiram um nível satisfatório de ajuste para cada sistema, resultando em um resíduo não correlacionado temporalmente ou, como também é denotado, ruído branco (RB).

Elevando os resíduos dos ajustes ao quadrado, a função de autocorrelação obtida não apresentou quaisquer defasagens significativas, caracterizando um RB (FIGURA 3.6). Dessa forma, as séries não apresentaram necessidade de ajuste de modelos para sua volatilidade.

Figura 3.6 - Gráficos da função de autocorrelação dos quadrados dos resíduos de cada modelo ajustado para as séries de a) autopropelido, b) gotejamento e c) sequeiro.



Fonte: Do autor (2020).

Os modelos resultantes para as diferentes séries foram obtidos conforme os parâmetros estabelecidos durante o ajuste. Visto que não houve a necessidade de ajustar modelos para volatilidade, apenas modelos SARIMA foram necessários para caracterizar as diferentes séries temporais estudadas, sendo eles:

– Sistema autopropelido:

$$(1 - B^{12}) Z_t = (1 + B^{12}) a_t \quad , \text{ sendo } a_t \sim \text{RB};$$

– Sistema de gotejamento:

$$(1 - B^{12}) (1 - B) Z_t = (1 + 0,59B^{12}) (1 + 0,75B) a_t \quad , \text{ sendo } a_t \sim \text{RB};$$

– Sistema de sequeiro:

$$(1 + 0,5B^{12}) (1 - B^{12}) Z_t = (1 + B^{12}) (1 - 0,89B) a_t \quad , \text{ sendo } a_t \sim \text{RB}.$$

Utilizando os dados observados do último ano de cada sistema de irrigação, reservados para quantificar o erro associado a cada modelo, verificou-se que houve menor erro no ajuste para o sistema autopropelido, seguido pelos sistemas de sequeiro e gotejamento, respectivamente (TABELA 3.3).

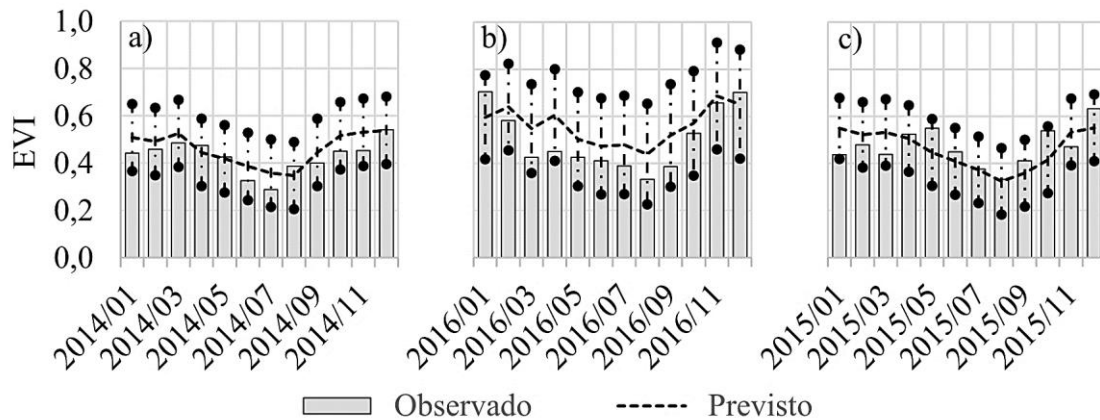
Tabela 3.3 - Erro associado aos dados previstos pelo modelo em relação aos dados observados.

Autopropelido			Gotejamento			Sequeiro		
Data	Obs.	Prev.	Data	Obs.	Prev.	Data	Obs.	Prev.
2014/01	0,442	0,509	2016/01	0,705	0,596	2015/01	0,437	0,549
2014/02	0,459	0,492	2016/02	0,583	0,640	2015/02	0,479	0,522
2014/03	0,485	0,526	2016/03	0,426	0,548	2015/03	0,438	0,532
2014/04	0,474	0,445	2016/04	0,450	0,606	2015/04	0,523	0,506
2014/05	0,426	0,419	2016/05	0,427	0,503	2015/05	0,550	0,447
2014/06	0,327	0,387	2016/06	0,411	0,473	2015/06	0,449	0,409
2014/07	0,289	0,358	2016/07	0,390	0,479	2015/07	0,376	0,373
2014/08	0,358	0,348	2016/08	0,332	0,440	2015/08	0,332	0,324
2014/09	0,401	0,445	2016/09	0,387	0,520	2015/09	0,411	0,359
2014/10	0,450	0,517	2016/10	0,527	0,571	2015/10	0,539	0,415
2014/11	0,453	0,531	2016/11	0,657	0,687	2015/11	0,471	0,534
2014/12	0,541	0,539	2016/12	0,702	0,652	2015/12	0,633	0,551
	MSPE:	0,003		MSPE:	0,010		MSPE:	0,005
	MAPE:	11,22%		MAPE:	19,24%		MAPE:	12,67%

Fonte: Do autor (2020).

Utilizando os modelos ajustados, foi possível gerar previsões dos valores de EVI para o ano subsequente a janela de observação utilizada para o ajuste dos modelos de cada sistema de irrigação (FIGURA 3.7). Verificou-se que as séries de EVI obtidas pelos modelos apresentaram correspondência semelhante aos dados observados ao longo de todo período utilizado para o ajuste, mesmo projetando-as um ano à frente dos dados observados.

Figura 3.7 - Valores de EVI estimados, com intervalo de predição (IP = 95%), para os 12 meses subsequentes as observações das lavouras sob sistema a) autopropelido, b) gotejamento e c) sequeiro.



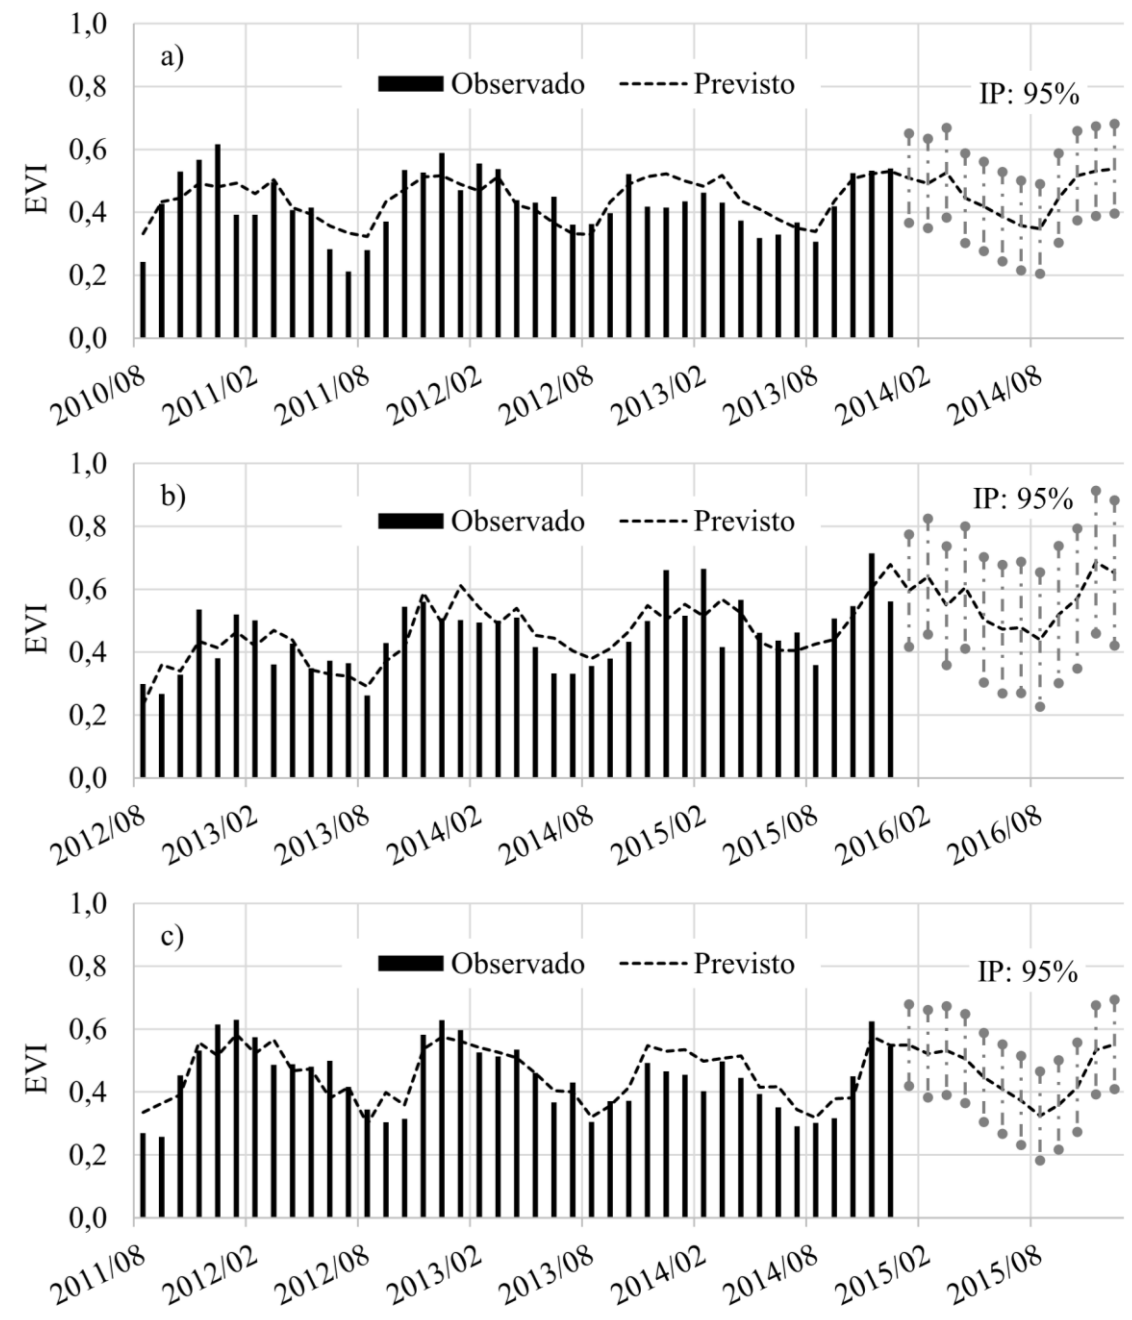
Fonte: Do autor (2020).

Baseando-se nas séries obtidas pelos modelos SARIMA de cada lavoura (FIGURA 3.8), observou-se que a lavoura sob sistema de irrigação autopropelido apresentou vigor vegetativo abaixo do esperado para o ano agrícola 2012/2013. De acordo com Pires *et al.* (2020), que realizaram estudos sobre ferrugem do cafeeiro na mesma área, a lavoura sob sistema de autopropelido apresentou incidência de ferrugem principalmente entre novembro de 2012 e agosto de 2013, indicando uma possível causa do desenvolvimento reduzido da lavoura durante esse período.

A lavoura sob sistema de irrigação por gotejamento apresentou vigor vegetativo abaixo do esperado para o ano agrícola de 2013/2014, iniciando em janeiro de 2014. Corroborando com essa observação, nesta mesma lavoura e durante o mesmo período, Miranda *et al.* (2020) observaram crescente ocorrência de necrose dos frutos de café, especialmente entre os meses de janeiro e março de 2014, podendo este evento ser o causador da divergência entre as séries observada e esperada para a lavoura.

Verificando a lavoura sob condição de sequeiro, observou-se que também houve redução do vigor vegetativo no ano agrícola de 2013/2014, seguindo abaixo do esperado a partir de dezembro de 2013. Conforme Pires *et al.* (2020), também foi observada incidência de ferrugem nessa lavoura, porém a partir de outubro de 2013, indicando que a série obtida pelo SARIMA não foi capaz de auxiliar na detecção de uma resposta espectral reduzida no mesmo mês que a amostragem foi realizada pelos autores, contudo, a série prevista contrastou o reflexo da ação do fitopatógeno no desenvolvimento do cafeeiro, tornando perceptível os impactos da ferrugem num sistema não irrigado.

Figura 3.8 - Valores de EVI estimados e observados, com intervalo de predição (IP), para os últimos cinco anos de observações das lavouras sob sistema a) autopropelido, b) gotejamento e c) sequeiro.



Fonte: Do autor (2020).

4 CONCLUSÕES

Com os modelos SARIMA foi possível descrever a variação espectro-temporal de lavouras cafeeiras sob diferentes sistemas de irrigação, com acurácia satisfatória, além de caracterizar a dinâmica de desenvolvimento da cultura.

Verificou-se que por meio de técnicas de análise de séries temporais foi possível determinar uma assinatura espectral esperada para o cafeeiro, o que pode auxiliar no estabelecimento de sistema de alertas quanto a identificação e necessidade de tomada de decisão a curto prazo nas lavouras cafeeiras, baseando-se na ocorrência de divergência negativa entre as séries observada e prevista pelos modelos.

REFERÊNCIAS

AKAIKE, H. A Bayesian extension of the minimum aic procedure of autoregressive model fitting. **Biometrika**, v. 66, n. 2, p. 237–242, 1979.

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 1 dez. 2013.

ARANTES, T. B. et al. Effectiveness of BFAST algorithm to characterize time series of dense forest, agriculture and pasture in the amazon region. **Theoretical and applied engineering**, v. 1, p. 10–19, 2017.

ATZBERGER, C. et al. Phenological metrics derived over the European continent from NDVI3g data and MODIS time series. **Remote Sensing**, v. 6, n. 1, p. 257–284, 2013.

BERNARDES, T. et al. Monitoring biennial bearing effect on coffee yield using MODIS remote sensing imagery. **International Geoscience and Remote Sensing Symposium (IGARSS)**, v. 5, p. 3760–3763, 2012.

BOX, G. E. P.; JENKINS, G. M. **Time series analysis: forecasting and control**. Holden-Day, 1970.

BOX, G. E. P.; PIERCE, D. A. Distribution of residual autocorrelations in discrete integrated moving average models. **Journal of American Statistical Association**, v. 65, n. 332, p. 1509–1526, 1970.

CHEMURA, A.; MUTANGA, O.; DUBE, T. Separability of coffee leaf rust infection levels with machine learning methods at Sentinel-2 MSI spectral resolutions. **Precision Agriculture**, v. 18, n. 5, p. 859–881, 2017a.

CHEMURA, A.; MUTANGA, O.; DUBE, T. Integrating age in the detection and mapping of incongruous patches in coffee (*Coffea arabica*) plantations using multi-temporal Landsat 8 NDVI anomalies. **International Journal of Applied Earth Observation and Geoinformation**, v. 57, p. 1–13, 2017b.

FINDLEY, D. F. Counterexamples to parsimony and BIC. **Annals of the Institute of Statistical Mathematics**, v. 43, n. 3, p. 505–514, 1991.

HAMILTON, L. C. **Regression with Graphics: A Second Course in Applied Statistics**. Duxbury Press, 1992.

HARRIS, E.; ABDUAL-AZIZ, A.; AVUGLAH, R. Modeling annual coffee production in ghana using arima time series model. **International Journal of Business and Social Research**, v. 2, n. 7, p. 175–186, 2012.

JUSTICE, C. O. et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): Land remote sensing for global change research. **Ieee Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1228–1249, 1998.

KÖPPEN, G. W.; GEIGER, M. R. Handbuch der klimatologie. **Bulletin of the American Geographical Society**, v. 43, n. 12, p. 935, 1936.

LATORRE, M. L. et al. MODIS sensor: General features and applications. **Espaço & Geografia**, v. 6, n. 1, p. 91–121, 2003.

MIRANDA, J. M. et al. Modelo matemático para previsão da produtividade do cafeeiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. 4, p. 353–361, 2014.

MIRANDA, R.; CARVALHO, M. DE; AMPÉLIO, E. Detection of coffee berry necrosis by digital image processing of landsat 8 oli satellite imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, n. November 2019, p. 01983, 2020.

MORETTIN, P. A.; DE CASTRO TOLOI, C. M. **Análise de séries temporais**. Edgard Blucher, 2006.

ORTEGA-HUERTA, M. A. et al. Mapping coffee plantations with Landsat imagery: An example from El Salvador. **International Journal of Remote Sensing**, v. 33, n. 1, p. 220–242, 2012.

PINDYCK, R. S.; RUBINFELD, D. L. **Econometric models and economic forecasts**. McGraw-Hill, 1991.

PIRES, M. S. DE O.; ALVES, M. DE C.; POZZA, E. A. Multispectral radiometric characterization of coffee rust epidemic in different irrigation management systems. **International Journal of Applied Earth Observation and Geoinformation**, v. 86, p. 1–15, abr. 2020.

PONZONI, F. J.; KUPLICH, T. M.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. Oficina de Textos, 2012.

ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1973.

SIN, C. Y.; WHITE, H. Information criteria for selecting possibly misspecified parametric models. **Journal of Econometrics**, v. 71, n. 1–2, p. 207–225, 1996.

TAUGOURDEAU, S. et al. Leaf area index as an indicator of ecosystem services and management practices: An application for coffee agroforestry. **Agriculture, Ecosystems and Environment**, v. 192, p. 19–37, 2014.

ZHANG, Z. et al. MODIS NDVI time series clustering under dynamic time warping.

International Journal of Wavelets, Multiresolution and Information Processing, v. 12, n. 05, p. 1461011, 2014.

CAPÍTULO 4

Monitoramento por meio de NDVI_{SAR} de Polarização Dupla para Áreas Cafeeiras sob Diferentes Sistemas de Irrigação

1 INTRODUÇÃO

O café é um dos produtos agrícolas de maior importância mundial e apresenta elevado impacto no desenvolvimento de países com produção cafeeira relevante no cenário econômico global. Atualmente, o maior produtor mundial de café é o Brasil e, de forma mais específica, apenas o estado de Minas Gerais representa mais da metade de toda produção da cultura (BERNARDES *et al.*, 2012; BRUNSELL; PONTES, 2009; OLIVEIRA *et al.*, 2012).

Dada a importância da produção cafeeira em escala global, é evidente que o monitoramento de seu desenvolvimento necessita de atenção proporcional. A implementação de um monitoramento adequado pode resultar desde melhorias em escala local, como a qualidade do produto *in natura* e seus derivados, até melhorias em escala internacional, como a determinação de políticas agrícolas e econômicas mais eficazes, colaborando com o desenvolvimento socioeconômico do país (MARUJO *et al.*, 2017; BRUNSELL; PONTES, 2009).

O uso do sensoriamento remoto orbital permite que o monitoramento agrícola seja realizado em larga escala, coletando um grande número de informações, com elevada densidade amostral, sem impactar significativamente em sua viabilidade operacional (MARUJO *et al.*, 2017; RAFAELLI; MOREIRA; FARIA, 2006).

Ao escolher o melhor sistema sensor para realizar o monitoramento da cultura, as resoluções de cada plataforma devem ser consideradas juntamente às suas condições de acesso aos dados. Diferentes plataformas apresentam diferentes relações entre seu poder de detalhamento geométrico da superfície, sensibilidade à resposta espectral dos alvos e tempo de revisita ao mesmo ponto imageados, sendo essas as resoluções espacial, espectral e temporal, respectivamente (BERNARDES *et al.*, 2012; MARUJO *et al.*, 2017; ORTEGA-HUERTA *et al.*, 2012; RAFAELLI; MOREIRA; FARIA, 2006).

Além da detecção direta de respostas espectrais dos alvos terrestres em comprimentos de ondas específicos, os dados resultantes do imageamento orbital também permitem estimar índices que correlacionam comportamentos espectrais intrínsecos dos alvos, aprimorando sua identificação, além de possibilitar descrever seu estado em meio ao agroecossistema em que

está inserido (HAILU *et al.*, 2015; NOGUEIRA; MOREIRA; VOLPATO, 2018; TAUGOURDEAU *et al.*, 2014).

O Índice de Vegetação pela Diferença Normalizada (NDVI) é um índice espectral que quantifica a proporção entre a reflectância de alvos terrestres em faixas de comprimento de onda eletromagnética do vermelho visível (620 – 670 nm) e infravermelho próximo (841 – 876 nm), permitindo não apenas identificar alvos vegetais em cenas inteiras, mas também estimar o vigor de seu desenvolvimento (ROUSE *et al.*, 1973).

Devido a própria natureza de obtenção do NDVI, seus valores estão diretamente relacionados as condições de turgor das folhas e atividade fotossintética dos alvos vegetais imageados, podendo assim, registrar assinaturas espectrais que podem variar entre culturas imageadas e, também, entre as condições de tratos culturais e manejos de irrigação que uma mesma cultura esteja submetida (PIRES; ALVES; POZZA, 2020).

Intuitivamente, além do vigor vegetativo, o NDVI tem grande utilidade no monitoramento de riscos eventuais para a produção agrícola, tendo sua eficiência comprovada em casos de monitoramento dos efeitos de geada e detecção de ocorrência de doenças fúngicas em lavouras cafeeiras (COUTO JÚNIOR *et al.*, 2013; KATSUHAMA *et al.*, 2018; RAFAELLI; MOREIRA; FARIA, 2006).

Apesar da grande aplicabilidade do NDVI, a resolução espacial do sensor pode dificultar a aquisição de informações sobre o alvo terrestre de interesse. Sistemas sensores de baixa ou moderada resolução espacial conseguem imagear grandes extensões de área, com menor detalhamento da superfície, o que permite elevar sua resolução espectral e/ou temporal, favorecendo monitoramentos com maior integridade temporal e gama de informações espectrais, ao risco de reduzir a acurácia de estudos quantitativos em escala de lavoura (RAFAELLI; MOREIRA; FARIA, 2006).

Contudo, sensores orbitais passivos são suscetíveis a fortes interferências pela ocorrência de nuvens regionais, resultando em períodos inteiros sem imageamento, principalmente durante estações chuvosas, inviabilizando análises de séries temporais, além de pôr em risco a acurácia do monitoramento contínuo da cultura (FILGUEIRAS *et al.*, 2019; RAFAELLI; MOREIRA; FARIA, 2006).

O uso de plataformas orbitais de sensoriamento ativo como o satélite *Sentinel-1*, que é um dispositivo de Detecção e Telemetria por Rádio (RADAR), tem sido empregado no intuito de superar as barreiras de nebulosidade no imageamento, favorecendo a continuidade temporal das informações terrestres obtidas (WOODHOUSE, 2005).

Em virtude da sua capacidade de emitir suas próprias ondas eletromagnéticas, com frequência controlada, o comprimento de onda emitido na escala de centímetros consegue ultrapassar partículas e gotículas de maior diâmetro suspensas na atmosfera, possibilitando realizar o imageamento através de nuvens, com reduzida ocorrência de espalhamentos e demais interferências atmosféricas (FILGUEIRAS *et al.*, 2019; KHABBAZAN *et al.*, 2019; WOODHOUSE, 2005).

O *Sentinel-1* apresenta resolução espacial de 10 metros/*pixel* além de resolução temporal com tempo de revisita de 12 dias. Entretanto, a resolução espectral reduzida é a contraposição às demais resoluções, apresentando apenas duas bandas em polarização verticalmente emitida, para o território Brasileiro (ESA, 2012; FILGUEIRAS *et al.*, 2019; KHABBAZAN *et al.*, 2019).

Em razão da resolução espectral reduzida do *Sentinel-1*, o ajuste de índices espectrais se faz um desafio. Todavia, a utilização de bandas em dupla polarização vertical vem sendo explorada, cujos estudos relatam a possibilidade de modelar índices espectrais que auxiliam na identificação de estádios fenológicos de culturas anuais, além de estimar sua biomassa com elevada acurácia, consistência temporal e alta resolução espacial, sem influência significativa de nebulosidade regional (CHANG; SHOSHANY; OH, 2018; FILGUEIRAS *et al.*, 2019; KHABBAZAN *et al.*, 2019; MYSHLYAKOV, 2016).


Considerando o cenário cafeeiro, referindo-se a uma cultura perene, o sensoriamento remoto ativo apresenta grande potencial de inovação, oferecendo a possibilidade de contornar um dos principais empecilhos que agem atualmente como gargalo no avanço do monitoramento da cultura em plataformas orbitais e aéreas. Diante do exposto, o objetivo desta pesquisa foi verificar a aplicabilidade do uso de dados provenientes do satélite *Sentinel-1* para o cálculo de índice da vegetação a partir de polarização dupla, para o monitoramento do desenvolvimento de lavouras cafeeiras sob diferentes sistemas de irrigação.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

O estudo foi conduzido observando-se quatro lavouras de *Coffea arabica* L., cultivar Acaiaí 474/19, localizadas no município de Carmo do Rio Claro, inserido na mesorregião sul/sudoeste do estado de Minas Gerais, Brasil (FIGURA 4.1). De acordo com a classificação climática proposta por Köppen e Geiger (1936) e regionalizada por Alvares *et al.* (2013), o local de estudo está inserido na classe de Clima mesotérmico subtropical úmido (Cwa), apresentando inverno seco e verão úmido.

Figura 4.1 - Localização dos talhões estudados no município de Carmo do Rio Claro - MG, sob manejo da irrigação por sequeiro (a), autopropelido (b), gotejamento (c) e pivô central (d).



Fonte: Do autor (2020).

As áreas estudadas foram adubadas conforme recomendações de Guimarães *et al.* (1999), seus tratos culturais incluíram controle de plantas invasoras por meio de capina e controle químico de pragas e doenças. As lavouras divergiram entre si considerando os sistemas de irrigação as quais estavam submetidas, sendo eles sequeiro, autopropelido, gotejamento e pivô central, em que, para os três últimos citados, a irrigação foi coordenada por meio de tensiômetros, atendendo a demanda de cada lavoura de forma independente (PIRES; ALVES; POZZA, 2020) (TABELA 4.1).

Tabela 4.1 - Detalhamento das lavouras utilizadas no estudo para aquisição de assinaturas espectrais do cafeeiro em Carmo do Rio Claro - MG.

ID	Sistema de irrigação	Idade	Recepa 2018/2019	Orientação das linhas de plantio (°)	Espaçamento (m/m)
a	Sequeiro	12	Não	157,33	3,6 x 0,7
b	Autopropelido	13	Não	28,45	3,5 x 0,7
c	Gotejamento	11	Não	18,95	3,6 x 0,7
d	Pivô Central	17	Não	87,54	4,0 x 0,5

Fonte: Do autor (2020) adaptado de Pires (2020).

2.2 Dados Orbitais

O banco de dados orbitais foi preparado com informações espectrais de cada lavoura para o ano agrícola de 2018/2019, utilizando de imagens obtidas pelo sistema sensor ativo *Sentinel-1* e pelo sistema sensor passivo *Sentinel-2*, utilizado como referência para o estudo (TABELA 4.2). Os dados de ambos satélites foram disponibilizados pela plataforma *Copernicus Open Access Hub*, sob domínio da *European Space Agency* (ESA).

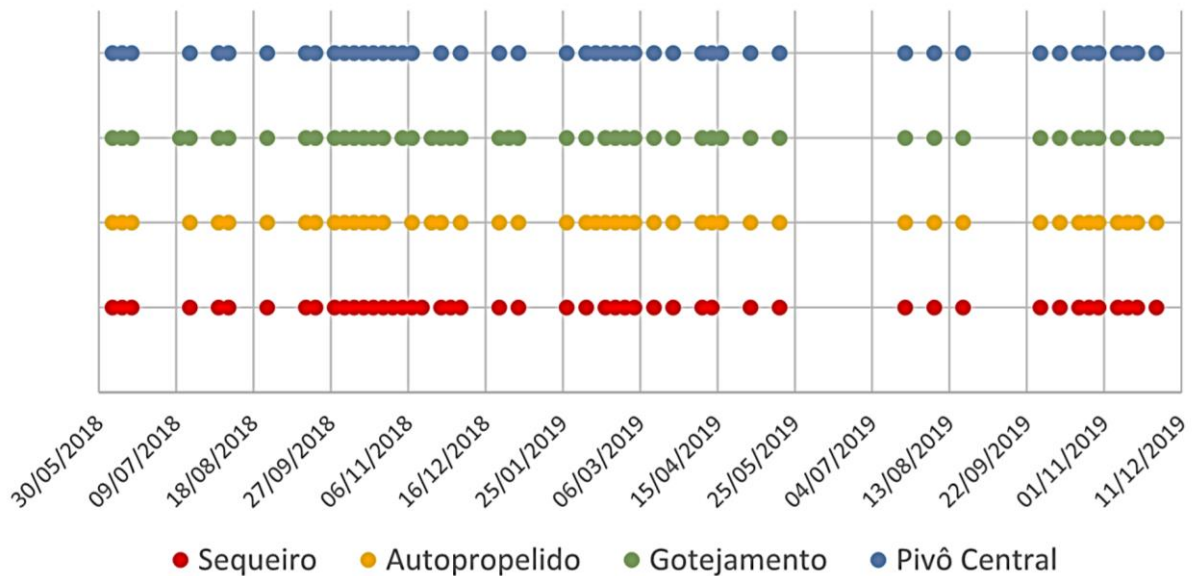
Tabela 4.2 - Especificações das plataformas orbitais e bandas utilizadas para aquisição de comportamentos espectrais das lavouras cafeeiras em Carmo do Rio Claro - MG.

ESPECIFICAÇÕES	<i>SENTINEL-1</i>	<i>SENTINEL-2A/B</i>
Sensor	Radar de Abertura Sintética - Banda C (C-SAR)	Instrumento Multiespectral (MSI)
Dimensões da Cena Imageada	250 x 200 km	100 x 100 km
Bandas Utilizadas	Banda - C (3,75 - 7,5 cm) Polarização Linear: Emissão e Recepção verticais (VV) Polarização Cruzada: Emissão Vertical e Recepção Horizontal (VH)	B4 - Vermelho Visível (650 - 680 nm) B8 - Infravermelho Próximo (784 - 900 nm)
Resolução Radiométrica	10 Bits	12 Bits
Resolução Espacial	5x20 metros/ <i>pixel</i> (IW) 10 metros/ <i>pixel</i> (pós-processada)	10 metros/ <i>pixel</i>
Resolução Temporal	12 dias	5 dias
Datum	WGS84	WGS84
Órbita	Heliossíncrona	Heliossíncrona
Altitude	693 km	786 km

Fonte: Do autor (2020) adaptado de ESA (2012).

Para o sensor passivo, totalizando 73 datas de observação, iniciando em 02/05/2018 e seguindo até 28/11/2019, com intervalos de cinco dias e excluindo as datas em que se registraram nebulosidade local identificadas pelos registros de *Quality Assessment* (QA) (FIGURA 4.2), foram obtidas imagens provenientes do satélite *Sentinel-2*, plataformas A e B. As cenas resultantes do imageamento foram submetidas ao pré-processamento via “*Sen2Cor*”, que visa corrigir efeitos atmosféricos presentes em produtos orbitais em primeiro nível de processamento (*Level-1*) de *Top-Of-Atmosphere* (TOA), convertendo-os em produtos orbitais de segundo nível de processamento (*Level-2*) de *Bottom-Of-Atmosphere* (BOA) (MAIN-KNORN *et al.*, 2017).

Figura 4.2 - Registro das datas em que as lavouras cafeeiras observadas em Carmo do Rio Claro – MG foram sobrepostas por nuvens entre maio/2018 e novembro/2019.

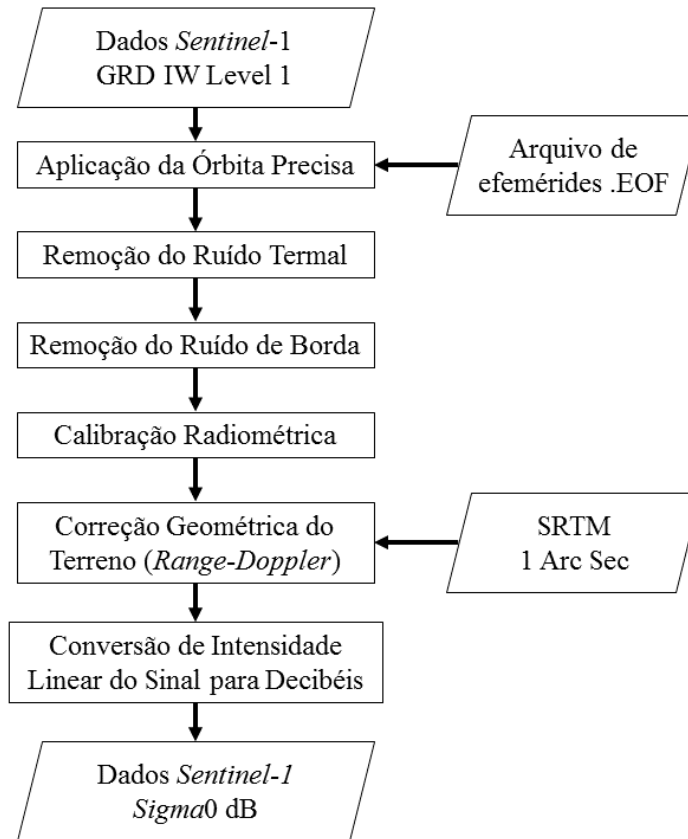


Fonte: Do autor (2020).

Para o sensor ativo, iniciando em 03/05/2018 e seguindo até 30/11/2019, foram obtidas cenas resultantes do imageamento realizado pelo satélite *Sentinel-1* plataforma B, em modo de aquisição *Interferometric Wide Swath* (IW) e nível de processamento *Ground Range Detected* (GRD), o qual foi obtido a partir do processo de focagem do sinal registrado no processo de visada múltipla dos dados SAR (ESA, 2012).

As imagens obtidas pelo satélite *Sentinel-1* foram submetidas ao procedimento de pré-processamento (FIGURA 4.3), para que fossem realizadas as etapas de aplicação de órbita precisa, calibração radiométrica, correção geométrica do terreno e remoção de ruídos termais e ruídos de borda, o que atenua o efeito ruidoso presente na imagem (FILIPPONI, 2019).

Figura 4.3 - Etapas de pré-processamento realizadas para correção e conversão dos dados de intensidade do satélite *Sentinel-1* para decibéis (dB).



Fonte: Adaptado de Filipponi (2020).

A filtragem do efeito *speckle* não foi realizada, visto que a mesma poderia eliminar informações relevantes da área, devido a escala de trabalho em relação a resolução espacial do sensor (GIR; JAIN; RAI, 2015).

O cálculo do Índice de Vegetação da Diferença Normalizada (NDVI) foi realizado para os dados orbitais obtidos pelo *Sentinel-2* conforme metodologia apresentada por Rouse *et al.* (1973) (Equação 11).

$$NDVI = \frac{NIR-RED}{NIR+RED}, \quad (11)$$

em que, NIR é a refletância da superfície registrada na faixa do infravermelho próximo e RED é a refletância da superfície registrada na faixa do vermelho visível. Considerando as bandas espectrais disponibilizadas pelo *Sentinel-2*, NIR e RED correspondem as bandas B8 e B4, respectivamente.

Analogamente, o cálculo do Índice de Vegetação da Diferença Normalizada por RADAR de Abertura Sintética ($NDVI_{SAR}$) foi realizado conforme metodologia apresentada por Myshlyakov (2016) e identificada similarmente como Proporção Normalizada entre Bandas (NRPB) por Filgueiras *et al.* (2019) (Equação 12).

$$NRPB = -NDVI_{SAR} = \frac{\sigma_{VH} - \sigma_{VV}}{\sigma_{VH} + \sigma_{VV}}, \quad (12)$$

em que, σ_{VH} é o retroespalhamento registrado em polarização cruzada e σ_{VV} é o retroespalhamento registrado em polarização linear vertical.

Os dados orbitais de ambos os sistemas sensores foram agrupados em suas respectivas médias mensais, para que as informações pudessem ser pareadas mesmo apresentando datas divergentes de imageamento.

2.3 Análises Estatísticas

Visando aproximar os índices obtidos de cada sensor orbital, as médias mensais de cada lavoura foram submetidas ao ajuste por Regressão Linear Simples (SLR) (Equação 13) para melhor estabelecer a relação entre os índices espectrais obtidos pelos sensores ativo e passivo (SCHITTKOWSKI, 2002).

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon, \quad i = 1, 2, \dots, n \quad (13)$$

Em que, Y_i é o NDVI obtido pelo *Sentinel-2* na observação i , x_i é o $NDVI_{SAR}$ obtido pelo *Sentinel-1* na observação i , β_0 é o coeficiente linear, β_1 é o coeficiente angular e ε é o erro aleatório associado ao ajuste.

Para avaliar os resultados obtidos pelos modelos ajustados foram adotadas as medidas de Erro Absoluto Médio (MAE) (Equação 14) e Erro Quadrático Médio (MSE) (Equação 15), que permitem verificar a diferença entre os valores observados e estimados, possibilitando quantificar a acurácia obtida em cada ajuste (LEHMANN; CASELLA, 1998; WILLMOTT; MATSUURA, 2005).

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|, \quad i = 1, 2, \dots, n \quad (14)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2, \quad i = 1, 2, \dots, n \quad (15)$$


em que, Y_i é o NDVI obtido pelo *Sentinel-2* na observação número i , \hat{Y}_i é o NDVI_{SAR} obtido pelo *Sentinel-1* na observação número i e n é número total de observações.

A validação dos ajustes ocorreu por meio do método de validação cruzada *Leave-One-Out* (LooCV), que é uma técnica derivada da validação cruzada *K-fold* (KOHAVI, 1995), porém com maior custo computacional por aplicar o modelo linear e quantificar o MSE iterativamente para cada observação, possibilitando que a validação seja executada mesmo com reduzido número de observações (MUKHERJEE; NIYOGI; POGGIO, 2002).

3 RESULTADOS E DISCUSSÃO

Foi observado que o NDVI_{SAR} obtido pelo *Sentinel-1*, mesmo com valores atenuados, registrou oscilações semelhantes às registradas pelo NDVI calculado pelo *Sentinel-2*, porém com maior separabilidade entre as assinaturas de cada sistema de irrigação (FIGURA 4.4).

Figura 4.4 - Séries temporais de NDVI_{SAR} e NDVI, obtidas pelos satélites *Sentinel-1* e *Sentinel-2* respectivamente, para lavouras cafeeiras sob diferentes sistemas de irrigação, localizadas no município de Carmo do Rio Claro - MG.



Fonte: Do autor (2020).

Observando as séries de NDVI e NDVI_{SAR}, verificou-se que ambas apresentam aumento aparente de seus valores entre os meses de outubro e fevereiro, atingindo seu máximo por volta dos meses de março e abril. Antagonicamente, verificou-se redução nos valores dos índices entre os meses de maio e agosto, atingindo seu mínimo em setembro.

O comportamento oscilatório apresentado ao longo do tempo descreve uma assinatura espectral tipicamente reconhecida no monitoramento orbital do cafeeiro, registrando seu vigor vegetativo desde o período pós-colheita da safra anterior e seguindo seu desenvolvimento por suas demais fases fenológicas de enfolhamento (julho e agosto), florescimento (setembro) e produção e maturação dos frutos (outubro a abril), corroborando com os registros fenológicos realizados por Pereira *et al.* (2008) e Pezzopane *et al.* (2003), indicando satisfatória caracterização da cultura monitora por ambos sensores.

Após o ajuste dos modelos pela SLR, verificou-se que todos os coeficientes lineares (β_0) não foram significativos, com exceção do ajuste para o sistema de irrigação por gotejamento. Avaliando os coeficientes angulares (β_1), observou-se que a lavoura sob sistema de sequeiro apresentou menor coeficiente (1,74), enquanto as lavouras sob os demais sistemas de irrigação apresentaram coeficientes mais próximos, com valores entre 2,40 e 2,68 (TABELA 4.3).

Tabela 4.3 - Relatório dos dados obtidos a partir da SLR para cada lavoura cafeeira, sob diferentes sistemas de irrigação, localizada em Carmo do Rio Claro - MG.


	Parâmetros	Coefficientes	valor-P	MAE	MSE	LooCV R ²
Autopropelido	β_1	2,404	0,000 ***	0,078	0,008	0,495
	β_0	-0,078	0,656 n.s.			
Gotejamento	β_1	2,632	0,000 ***	0,173	0,032	0,518
	β_0	-0,101	0,048 **			
Pivô Central	β_1	2,682	0,000 ***	0,108	0,014	0,563
	β_0	-0,108	0,458 n.s.			
Sequeiro	β_1	1,744	0,002 ***	0,150	0,026	0,397
	β_0	0,150	0,312 n.s.			

n.s = Não significativo; ** = Significativo com α a 5%; *** = Significativo com α a 1%.

Fonte: Do autor (2020).

Aplicando-se os coeficientes ajustados para cada sistema de irrigação, observou-se que as séries de $NDVI_{SAR}$ foram reajustadas, com valores mais próximos aos registradas pelo NDVI do *Sentinel-2*. Assim como já indicado pelos coeficientes angulares apresentados anteriormente, verificou-se que o $NDVI_{SAR}$, propiciou clara separação entre a lavoura sob sistema de sequeiro e as demais lavouras avaliadas, considerando valores médios abaixo e acima de 0,6, respectivamente (FIGURA 4.5).

Figura 4.5 - Séries temporais de $NDVI_{SAR}$ obtidas pelo satélite *Sentinel-1* e ajustadas pelos parâmetros da regressão linear simples, para lavouras cafeeiras sob diferentes sistemas de irrigação, localizadas no município de Carmo do Rio Claro - MG.

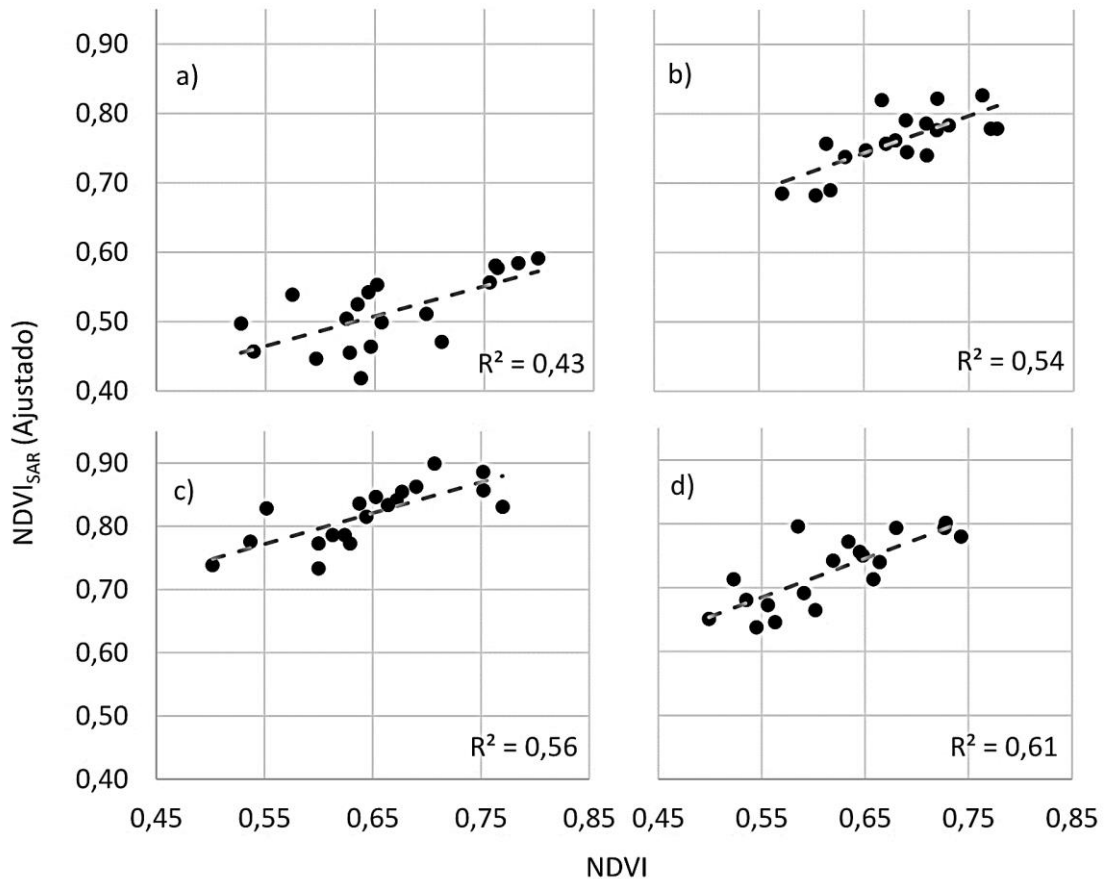


Fonte: Do autor (2020).

As assinaturas obtidas pelo $NDVI_{SAR}$ ressaltaram a variação sazonal no vigor vegetativo das lavouras cafeeiras, discretizando a lavoura submetida ao regime de sequeiro das demais. Este fenômeno pode ser explicado devido ao crescimento das plantas, desenvolvimento dos ramos ortotrópicos e plagiotrópicos, e do diâmetro da copa das plantas de café, que ocorre em todos os sistemas de irrigação observados, porém, de forma menos expressiva em lavouras sob manejo de sequeiro, tal qual observado nos estudos realizados por Carvalho *et al.* (2006) e Brito Ferreira *et al.* (2013).

Utilizando gráficos de dispersão para realizar uma comparação direta entre os valores obtidos pelos índices de cada satélite, foi possível verificar que o $NDVI_{SAR}$ subestimou os valores, se comparados aos do NDVI, para a lavoura sob condição de sequeiro, enquanto, de forma contrária, os valores foram superestimados para as demais condições de irrigação, mantendo uma relação linear satisfatória (FIGURA 4.6).

Figura 4.6 – Dispersões entre os valores obtidos pelo NDVI e NDVI_{SAR} ajustado, de maio de 2018 à novembro de 2019, para as lavouras cafeeiras de Carmo do Rio Claro - MG, sob os sistemas de irrigação (a) sequeiro, (b) autopropelido, (c) gotejamento, (d) pivô central.




Fonte: Do autor (2020).

O nível moderado dos coeficientes de determinação observados pela comparação direta entre os índices obtidos pelo *Sentinel-1* e *Sentinel-2* indica que o NDVI_{SAR}, apesar de não ser equiparado ao NDVI convencional, pode ter sua aplicação focada em disponibilizar dados de vigor vegetativo durante períodos nebulosos, nos quais sensores passivos não conseguem realizar o imageamento da superfície terrestre, tal qual apresentado por Filgueiras *et al.* (2018).

Com base na ideia de utilizar o NDVI_{SAR} como fonte de informação auxiliar para regiões com alta ocorrência de nuvens, verificou-se a assinatura de NDVI e NDVI_{SAR}, para as quatro lavouras durante período de maio/2018 à novembro/2019, considerando as resoluções temporais das respectivas plataformas orbitais (FIGURA 4.7).

Figura 4.7 – Assinaturas de NDVI com datas nebulosas, NDVI após remoção de dados incertos pelo QA e NDVI_{SAR} ajustado, de maio de 2018 à novembro de 2019, para as lavouras cafeeiras de Carmo do Rio Claro - MG, sob os diferentes sistemas de irrigação.

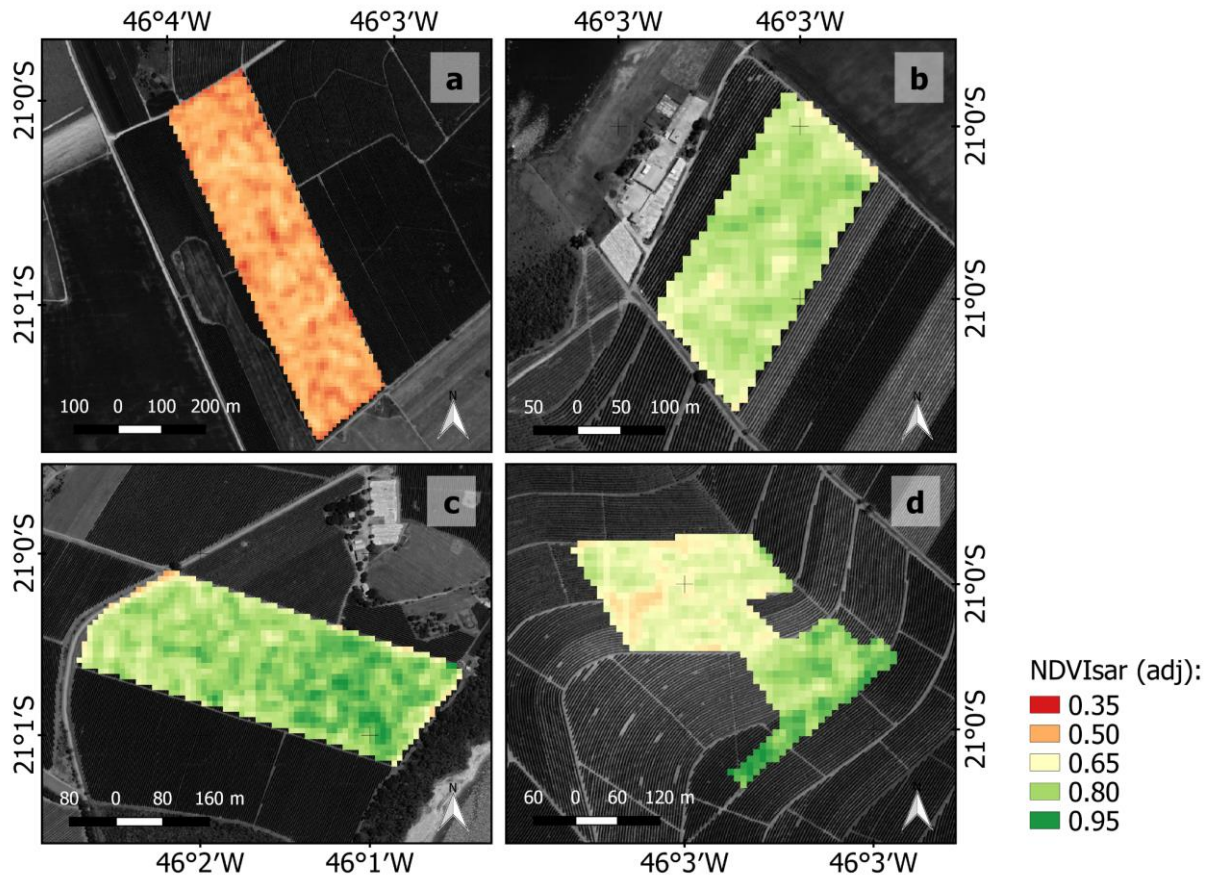


Fonte: Do autor (2020).

Observou-se que mesmo realizando a limpeza dos dados do *Sentinel-2* com base nas informações de QA, além dessa etapa resultar em descontinuidade na série temporal, algumas datas ainda apresentaram variações bruscas, indicando possíveis ruídos existentes durante o imageamento da área. Dessa forma, o *Sentinel-1* pode ser uma fonte complementar de dados espectrais, auxiliando, principalmente, em estudos que envolvam análises de séries temporais em regiões que não favorecem a estruturação de um banco de dados geográfico temporalmente contínuo em virtude de suas condições climáticas corriqueiras.

Os coeficientes resultantes do ajuste linear entre os índices espectrais obtidos pelos satélites *Sentinel-1* e *Sentinel-2* foram aplicados diretamente nas imagens disponibilizadas pelo *Sentinel-1*, de forma condicional para cada sistema de irrigação (FIGURA 4.8).

Figura 4.8 - NDVI_{SAR} ajustado médio para o ano agrícola 2018/2019, considerando os talhões cafeeiros sob manejo da irrigação por sequeiro (a), autopropelido (b), gotejamento (c) e pivô central (d), observados no município de Carmo do Rio Claro - MG.



Fonte: Do autor (2020).

Foi possível verificar que apesar das lavouras apresentarem variações internas, a lavoura sob sistema de gotejamento apresentou maior vigor médio durante o ano agrícola de 2018/2019, seguido pelos sistemas autopropelido, pivô central e, com menor vigor, a lavoura sob condição de sequeiro. Em especial, atentando para o pivô central, observou-se que os vigores vegetativos das plantas de café apresentaram divergências entre seus setores noroeste e sudeste, indicando possível reflexo da ocorrência de pragas e doenças como já constatada na mesma lavoura por Oliveira Pires *et al.* (2020) e por Miranda *et al.* (2020).

4 CONCLUSÕES

Os dados provenientes do satélite *Sentinel-1* possibilitaram o cálculo de um índice espectral da vegetação para lavouras cafeeiras sob diferentes sistemas de irrigação no município de Carmo do Rio Claro - MG.

Mesmo disponibilizando apenas duas polarizações para o território brasileiro, o NDVI_{SAR} permitiu verificar o vigor vegetativo do cafeeiro ao longo de seu desenvolvimento, além de distinguir a lavoura sob sistema de sequeiro das demais, mesmo estando submetida aos mesmos tratos culturais, sem apresentar sinais de recepa durante o período de observação e com idade semelhante aos sistemas de gotejamento e autopropelido.

Considerando a similaridade entre os índices espectrais de cada satélite, verificada no presente estudo, o *Sentinel-1* pode ser utilizado como fonte auxiliar para obtenção de informações quanto ao vigor vegetativo de lavouras cafeeiras em momentos que os sensores passivos ficarem obstruídos por nuvens, independentemente do sistema de irrigação, com elevada constância temporal.

REFERÊNCIAS

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 1 dez. 2013.

BERNARDES, T. et al. Monitoring biennial bearing effect on coffee yield using MODIS remote sensing imagery. **International Geoscience and Remote Sensing Symposium (IGARSS)**, v. 5, p. 3760–3763, 2012.

MARUJO, R. DE F. B. et al. Coffee crop detection by automatic classification of illumination. p. 17–28, 2017.

BRUNSELL, N. A.; PONTES, P. P. B. Remotely sensed phenology of coffee and its relationship to yield. **GIScience and Remote Sensing**, v. 46, n. 3, p. 289–304, 2009.

CARVALHO, C. H. M. DE et al. Evolução do crescimento do cafeeiro (*Coffea arabica* L.) irrigado e não irrigado em duas intensidades de plantio. **Ciência e Agrotecnologia**, v. 30, n. 2, p. 243–250, 2006.

CHANG, J. G.; SHOSHANY, M.; OH, Y. Polarimetric RADAR vegetation index for biomass estimation in desert fringe ecosystems. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 12, p. 7102–7108, 2018.

COUTO JÚNIOR, A. F. et al. Phenological characterization of coffee crop (*Coffea arabica* L.) from MODIS time series. **Revista Brasileira de Geofísica**, v. 31, n. 4, p. 569–578, 2013.

DE BRITO FERREIRA, E. P. et al. Crescimento vegetativo de *coffea arabica* l. influenciado

por irrigação e fatores climáticos no cerrado goiano. **Semina: Ciências Agrárias**, v. 34, n. 6 SUPPL. 1, p. 3235–3244, 2013.

ESA. ESA's radar observatory mission for GMES operational services. **ESA Special Publication**, v. 1, n. sp-1322/1, p. 88, 2012.

FILGUEIRAS, R. et al. Crop NDVI monitoring based on Sentinel-1. **Remote Sensing**, v. 11, n. 12, 2019.

FILIPPONI, F. Sentinel-1 GRD Preprocessing Workflow. **Proceedings**, v. 18, n. 1, p. 11, 2019.

GIR, R.; JAIN, L.; RAI, R. Speckle reduction of synthetic aperture radar images using median filter and savitzky-golay filter. **International Journal of Computer Applications**, v. 113, n. 11, p. 38–43, 2015.

GUIMARÃES, P. T. G.; ALVAREZ, V. H.; RIBEIRO, A. C. **5ª Aproximação - Recomendações para o uso de corretivos e fertilizantes em Minas Gerais**. v.1, n.1, 322 p., 1991.

HAILU, B. T. et al. Identifying potential areas of understorey coffee in Ethiopia's highlands using predictive modelling. **International Journal of Remote Sensing**, v. 36, n. 11, p. 2898–2919, 2015.

KATSUHAMA, N. et al. Discrimination of areas infected with coffee leaf rust using a vegetation index. **Remote Sensing Letters**, v. 9, n. 12, p. 1168–1194, 2018.

KHABBAZAN, S. et al. Crop monitoring using sentinel-1 data: A case study from the netherlands. **Remote Sensing**, v. 11, n. 16, p. 1887, 2019.

KOHAVI, R. **A study of cross-validation and bootstrap for accuracy estimation and model selection**. International Joint Conference of Artificial Intelligence. **Anais...: IJCAI'95**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., out. 1995.

KÖPPEN, G. W.; GEIGER, M. R. Handbuch der klimatologie. **Bulletin of the American Geographical Society**, v. 43, n. 12, p. 935, 1936.

LEHMANN, E. L.; CASELLA, G. **Theory of point estimation , second edition Springer texts in statistics**. v. 41.

MAIN-KNORN, M. et al. **Sen2Cor for Sentinel-2**. procs pie. **Anais...: Society of Photo-Optical Instrumentation Engineers (SPIE) Conference Series**. 2017.

MIRANDA, J. DA R. et al. Detection of coffee berry necrosis by digital image processing of landsat 8 oli satellite imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, n. November 2019, p. 101983, 2020.

MUKHERJEE, S.; NIYOGI, P.; POGGIO, T. Statistical Learning : Well-posedness is necessary and sufficient for consistency of empirical risk minimization. December, p. 0–24, 2002.

- MYSHLYAKOV, S. G. Sentinel-1 radar capabilities for agricultural applications. **GEOMATICS**, v. 2, n. 2, p. 16–24, 2016.
- NOGUEIRA, S. M. C.; MOREIRA, M. A.; VOLPATO, M. M. L. Relationship between coffee crop productivity and vegetation indexes derived from OLI / Landsat-8 sensor data with and without topographic correction. **Engenharia Agrícola**, v. 38, n. 3, p. 387–394, 2018.
- OLIVEIRA, K. M. G. et al. Modelagem para a estimativa da orientação de linhas de plantio de cafeeiros. **Engenharia Agrícola**, p. 57–77, 2012.
- ORTEGA-HUERTA, M. A. et al. Mapping coffee plantations with land sat imagery: An example from El Salvador. **International Journal of Remote Sensing**, v. 33, n. 1, p. 220–242, 2012.
- PEREIRA, A. R.; DE CAMARGO, Â. P.; DE CAMARGO, M. B. P. **Agrometeorologia de cafezais no Brasil**. Campinas: Instituto Agrônomico, 2008.
- PEZZOPANE, J. R. M. et al. Escala para avaliação de estádios fenológicos do cafeeiro arábica. **Bragantia**, v. 62, n. 3, p. 499–505, 2003.
- PIRES, M. S. DE O.; ALVES, M. DE C.; POZZA, E. A. Multispectral radiometric characterization of coffee rust epidemic in different irrigation management systems. **International Journal of Applied Earth Observation and Geoinformation**, v. 86, p. 102016, abr. 2020.
- RAFAELLI, D. R.; MOREIRA, M. A.; FARIA, R. T. DE. Analysis of the MODIS data potential to monitor (state and local level) frost impact on coffee. **Agricultura em Sao Paulo**, n. 53, p. 5–15, 2006.
- ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1973.
- SCHITTKOWSKI, K. **Numerical data fitting in dynamical systems: A practical introduction with applications and software**. Norwell, MA, USA: Kluwer Academic Publishers, 2002.
- TAUGOURDEAU, S. et al. Leaf area index as an indicator of ecosystem services and management practices: An application for coffee agroforestry. **Agriculture, Ecosystems and Environment**, v. 192, p. 19–37, 2014.
- WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate Research**, v. 30, n. 1, p. 79–82, 2005.
- WOODHOUSE, I. H. **Introduction to microwave remote sensing**. CRC Press, 2005.