

V.21 nº44 (2025)


REVISTA DA
**AN
PE
GE**

ISSN 1679-768X

a

ANPEGE

Associação Nacional
de Pós-graduação e
Pesquisa em Geografia



DOSSIÊ GEOGRAFIA BRASILEIRA NA UGI

Integração de imagens multitemporais e multissensores para mapeamento de café com google earth engine

Integration of multi-temporal images and multisensors for coffee mapping with google earth engine

Integración de imágenes multitemporal y multisensores para mapeo de café con google earth engine

DOI: 10.5418/ra2025.v21i44.19756

MARIA CECILIA MANOEL

Universidade de São Paulo (USP)

ALFREDO PEREIRA DE QUEIROZ

Universidade de São Paulo (USP)

MARCOS REIS ROSA

Universidade de São Paulo (USP)

V.21 n°44 (2025)

e-issn : 1679-768X

RESUMO: Esta pesquisa investigou a integração de imagens dos satélites Landsat 8 (L8), Sentinel-2 (S2) e Sentinel-1 (S1) com os índices de vegetação (NDVI, EVI, SAVI e NDWI). Foram comparadas duas áreas de estudo: a região Média Mogiana e o município de Espírito Santo do Pinhal, ambos localizados no estado de São Paulo. A característica bienal de produção do café foi adotada para a definição de ciclos de análise (de 2017 a 2023). A seleção das imagens, criação dos índices, classificação (Random Forest) e a verificação da acurácia foram realizados na plataforma de processamento em nuvem Google Earth Engine. Os resultados evidenciaram a relevância da integração de imagens multitemporais e multissensores para as classificações de uso e ocupação da terra, com acurácia global de 90,2% e, para mapeamentos de café, com acurácia do produtor de 91%, indicando poucas omissões de áreas de plantios desse cultivo.

Palavras-chave: café, gee, landsat 8, sentinel-2, sentinel-1.

ABSTRACT: This research investigated the integration of Landsat 8, Sentinel-2 and Sentinel-1 images with vegetation indices (NDVI, EVI, SAVI and NDWI). Two study areas were compared: the Média Mogiana region and the municipality of Espírito Santo do Pinhal, both located in the state of São Paulo. The biennial characteristic of coffee production was adopted to define analysis cycles (from 2017 to 2023). The selection of images, creation of indices, classification (Random Forest) and accuracy verification were carried out on the Google Earth Engine cloud processing platform. The results highlighted the relevance of integrating multi-temporal and multi-sensor images for land use and occupation classifications, with a global accuracy of 90.2% and, for coffee mapping, with a producer accuracy of 91%, indicating few omissions of planting areas for this crop.

Keywords: coffee, gee, landsat 8, sentinel-2, sentinel-1.

RESUMEN: Esta investigación investigó la integración de imágenes Landsat 8, Sentinel-2 y Sentinel-1 con índices de vegetación (NDVI, EVI, SAVI y NDWI). Se compararon dos áreas de estudio: la región del Média Mogiana y el municipio de Espírito Santo do Pinhal, ambos ubicados en el estado de São Paulo. Se adoptó la



característica bienal de la producción de café para definir los ciclos de análisis (de 2017 a 2023). La selección de imágenes, creación de índices, clasificación (Random Forest) y verificación de precisión se realizaron en la plataforma de procesamiento en la nube Google Earth Engine. Los resultados resaltaron la relevancia de integrar imágenes multitemporales y multisensores para las clasificaciones de uso y ocupación de la tierra, con una precisión global del 90,2% y, para el mapeo del café, con una precisión del productor del 91%, lo que indica pocas omisiones de las áreas de plantación para este cultivo.

Palabras clave: café, gee, landsat 8, sentinel-2, sentinel-1.

Introdução

A necessidade de compreender o dinâmico processo de uso e ocupação da terra tem influenciado as análises e interpretações de dados geoespaciais, refletindo na elaboração de classificações que abordem a relação homem-natureza, tanto no âmbito da análise da cobertura vegetal, quanto dos avanços das ações antrópicas sobre o meio (Chaves; Picoli; Sanches, 2020; Phiri et al., 2020). Paralelamente, o avanço das geotecnologias tem revolucionado a abordagem de monitoramento e gestão de elementos da superfície terrestre, permitindo mapeamentos em diferentes escalas (Phiri et al. 2020). Essas mudanças implicaram no aumento da produção de dados e impactou o uso dos Sistemas de Informações Geográficas (SIG) (Hunt et al., 2020; Tamiminia et al., 2020).

Esse cenário permitiu a popularização do uso de plataformas de processamento e análise de dados geoespaciais em nuvem, principalmente na área de Sensoriamento Remoto, devido a capacidade de compartilhamento, acesso de dados de diferentes sensores, além da possibilidade de usar e criar algoritmos para tarefas simples e complexas. (Kelley; Pitcher; Bacon, 2018; Hunt et al., 2020; Maskell, et al., 2021). Entre as plataformas existentes, o Google Earth Engine (GEE) obteve destaque no meio acadêmico pelo seu potencial de visualizar, processar e analisar grandes volumes de imagens de satélite e outros dados geoespaciais de forma eficiente (Tamiminia et al., 2020).

Dentre as diversas possibilidades, os mapeamentos agrícolas no GEE apresentam um potencial para contribuir com a tomada de decisão de órgãos públicos e privados, além de pautar questões estratégicas em diferentes escalas (Kelley; Pitcher; Bacon, 2018; Hunt et al., 2020; Maskell et al., 2021). Mapear áreas de cultivo é um pré-requisito para prever rendimentos, produzir métricas, detectar doenças e monitorar atividades agrícolas. Devido ao elevado custo dessas tarefas, o GEE tem sido um grande aliado do setor (Adrian; Sagan; Maimaitijiang, 2021), pela capacidade de produzir classificações rápidas, confiáveis e acessíveis para diferentes tipos de culturas (Phiri et al., 2020).

O café Arábica (*Coffea arabica*), *commodity* agrícola com grande importância nacional e mundial, se difere de outras culturas perenes, devido à sua bienalidade, ou seja, a planta completa seu ciclo de produção a cada dois anos (CONAB, 2024). Esse cultivo, bastante expressivo no Brasil, também se acontece em outros países onde há ocorrência frequente de chuvas ou nebulosidade, o que representa grandes desafios na classificação de imagens de satélite, já que esses fenômenos atmosféricos afetam a qualidade de sensores ópticos (Sun et al., 2019; Maskell et al., 2021). As particularidades dos locais de plantio (plantados em sol pleno, sombreado ou em sistemas agroflorestais) e a alta heterogeneidade dos cultivos do seu entorno, dificultam a definição de métodos de mapeamentos universais, sendo, portanto, necessário avaliar condições específicas de cada área de estudo, para reduzir as incertezas e melhorar os resultados (Escobar-López et al., 2024).

Com intuito de minimizar os desafios existentes, foi utilizado o conceito de fusão de imagens com diferentes composições de bandas e dados auxiliares. A associação ou fusão de imagens selecionadas em um determinado período de tempo, conhecidas como multitemporais, e imagens geradas por diferentes sensores, conhecidas como imagens multissensores, é considerada uma estratégia para melhorar a classificação e o mapeamento de culturas diversas (Sun et al., 2019; Chaves; Picoli; Sanches, 2020), entre elas, o café (Cordero-Sancho; Sader, 2007; Chemura et al., 2018; Hunt et al., 2020; Maskell et al., 2021). A integração entre Landsat 8 OLI (*Operational Land Imager*) TIRS (*Thermal Infrared Sensor*) e Sentinel-2 MSI (*MultiSpectral Instrument*) Level-2A se destacam para a classificação de imagens oriundas de multissensores (Chaves; Picoli; Sanches, 2020). Essa composição possui vantagens em relação à: 1) resolução temporal e revisita do satélite (Sun et al., 2019), 2) resolução espacial (Hunt et al., 2020) e 3) resolução espectral (Chaves; Picoli; Sanches, 2020).

A fusão de dados do Sentinel-1 Banda C SAR (*Synthetic Aperture Radar*) GRD (*Ground Range Detected*) (S1) ao L8 e S2, apesar de ser uma metodologia pouco utilizada (Phiri et al., 2020; Adrian; Sagan; Maimaitijiang, 2021), apresenta grande potencial, pois colabora para aumentar a precisão da classificação (Sun et al., 2019; Hunt et al., 2020). Os dados S1 são úteis para extrair informações de áreas de plantio e identificar diferentes tipos de culturas (Chaves; Picoli; Sanches, 2020). Esta tecnologia melhora a aquisição de dados em períodos decisivos de monitoramento, já que não depende da iluminação solar e da cobertura de nuvens (Chemura et al., 2018; Hunt et al., 2020; Maskell et al., 2021).

O uso de dados auxiliares, em associação aos dados espectrais, como modelos digitais de elevação do terreno, mapas de temperatura ou precipitação, que fornecem informações complementares, são muito utilizados para aperfeiçoar a classificação geral de imagens (Phiri et al., 2020). No caso do café, se destacam a integração de dados topográficos (Hunt et al., 2020), climáticos (Kelley; Pitcher; Bacon, 2018), e índices de vegetação (Cordero-Sancho; Sader, 2007; Chemura et al., 2018). Os índices de vegetação mais usados são: *Normalized Difference Vegetation Index* (NDVI), que é sensível à clorofila e útil para comparar mudanças sazonais de crescimento da vegetação; o *Enhanced Vegetation Index* (EVI) que auxilia nas correções de ruído atmosférico e permite melhor distinção em locais com alta densidade de cultivos; o *Soil Adjusted Vegetation Index* (SAVI) que minimiza o brilho do solo e pode melhorar a distinção de áreas de plantio e solo exposto; e o *Normalized Difference Water Index* (NDWI) relevante para medir o conteúdo de água na vegetação (Chaves; Picoli; Sanches, 2020).

O objetivo da pesquisa é comparar os mosaicos de imagens multitemporais e de diferentes sensores na classificação do café arábica, de 2017 a 2023, na região da Média Mogiana e no município de Espírito Santo do Pinhal (São Paulo). Dados dos satélites Landsat 8, Sentinel-2, Sentinel-1 e os índices de vegetação NDVI, EVI, SAVI e NDWI foram utilizados nos mosaicos para a classificação do cultivo cafeeiro. No GEE, foram criadas sete classes de uso e ocupação da terra e o algoritmo de aprendizado de máquina Random

Forest (RF) foi utilizado para realizar as classificações. Acredita-se que a análise da acurácia global das classes de uso da terra e dos erros de classificação do café representam uma contribuição relevante, pois as informações sobre a extensão e a localização de áreas de cultivo de café pode auxiliar pequenos produtores para tomada de decisões, assim como órgãos públicos para a destinação de investimentos mais adequados, visando melhorias da produção em nível regional e municipal (Hunt et al., 2020).

2 O Café Arábica

2.1 Origens

O consumo e o cultivo de café são originários do continente africano, mais precisamente da Etiópia, onde animais se alimentavam das folhas da planta (Moreira, 2009). As técnicas de infusão dos frutos foram disseminadas pelos árabes posteriormente, para fins medicinais (Malavolta et al., 1974). O processo de torrefação e a forma de consumo que conhecemos hoje em dia, só ocorreu no século XIV na península Arábica, assim como a produção para fins comerciais (Martins, 1986).

As primeiras mudas de café adentraram no continente americano pela América Central e América do Sul. No Brasil, as primeiras plantas chegaram ao estado do Pará pela Guiana Francesa, por volta do século XVIII e, por interesses comerciais, foi levada ao estado do Rio de Janeiro, disseminando-se pela Serra do Mar e Vale do Paraíba, chegando aos estados de São Paulo e Minas Gerais (Moreira, 2009). No século XIX, São Paulo se tornou o principal produtor nacional e o Brasil se destacou no mercado mundial, marcando assim o auge do cultivo de café no país (Martins, 1986).

Segundo a Organização Internacional do Café (IOC, 2024), existem plantações em 72 países, concentrados na região intertropical, na América do Sul, América Central e Ásia. O Brasil se destaca no mercado internacional como maior produtor e exportador mundial de café (ABIC, 2024). Atualmente, Minas Gerais é o maior produtor cafeeiro nacional, seguido de São Paulo, onde está localizada a região Mogiana, considerada a mais produtiva do estado (CONAB, 2024). Do ponto de vista geográfico, é dividida em: Alta Mogiana (região de Franca, Batatais e Ribeirão Preto) e Média Mogiana (região de São João da Boa Vista, Mogi Guaçu, Bragança Paulista e Espírito Santo do Pinhal), sendo esta considerada a maior em área de plantação de café (CIIAGRO, 2024).


Existem diferentes espécies de cafés cultivados no mundo, entre as quais se destaca o *coffea arábica*, mais conhecido como Arábica. Sua particularidade é a produção bienal, ou seja, o cafeeiro produz frutos a cada dois anos, diferentemente da espécie *coffea canephora*, por exemplo, que tem uma produção anual (CONAB, 2024). A qualidade do seu grão associada à ampla produção mundial, faz com que o Arábica represente o tipo de café mais consumido no mundo (ABIC, 2024).

Bienalidade

O café Arábica apresenta diferentes fases de desenvolvimento, influenciado por fatores da espécie e por fatores externos. Segundo Pereira, Angelocci e Sentelhas (2002), o desenvolvimento pode ser dividido em três fases: 1) Crescimento até a fase adulta (entre 4 e 7 anos de vida); 2) Período de Produção (por volta de 25 anos); 3) Fase de declínio e morte da planta. O cafeeiro é muito sensível às mudanças do ambiente, principalmente alterações dos padrões de chuva e de temperatura, que podem comprometer safras inteiras (Camargo; Camargo, 2001).

O período de produção bienal é dividido em duas fases: 1) Vegetativa (vegetação e formação das gemas florais); 2) Reprodutiva (florada, frutos e senescência). A Figura 1 representa essas fases.

Figura 1 – Ilustração das fases de produção bienal do café Arábica



Fonte: CONAB (2024).

Segundo CIIAGRO (2024), o café Arábica se desenvolve em locais com temperaturas entre 18°C e 22°C e precipitações médias anuais entre 1200 e 2000 mm. As altitudes que favorecem o desenvolvimento dessa espécie variam entre 600 e 2000 metros. Sombras parciais também favorecem o desenvolvimento dos frutos e a qualidade da bebida, contudo, a produção comercial mais comum é o plantio em pleno sol, no qual a produtividade é mais elevada (CONAB, 2024).

Sua produtividade é bastante impactada pelas alterações climáticas, e a fase reprodutiva (florada, granação e maturação dos frutos) é a mais crítica (Camargo; Camargo, 2001). Temperaturas acima de 30°C podem afetar o crescimento e o desenvolvimento do grão, assim como as chuvas irregulares que, em excesso,

podem gerar o abortamento das flores e, a escassez, pode produzir grãos mal formados e irregulares, prejudicando a qualidade do produto (CIIAGRO, 2024).

Os padrões climáticos determinam os ciclos bienais do café arábica. No Brasil, Camargo; Camargo (2001), descreveram a divisão desses períodos de acordo com as variações ao longo do ano (Figura 2). Essas influências climáticas definiram os ciclos de produção de café avaliados nessa pesquisa (ano bienal 1 e ano bienal 2).

Figura 2 – Fases de produção bienal do café Arábica

A no Bi en al 1	I. Fase vegetativa (Baixa Produção)	Vegetação e formação das gemas florais	Período úmido	Setembro a março
		Indução e maturação das gemas florais	Período seco	Abril a agosto
A no Bi en al 2	II. Fase Reprodutiva (Alta produção)	Florada, chumbinho e expansão dos frutos	Período úmido	Setembro a dezembro
		Granação dos frutos		Janeiro a março
		Maturação dos frutos	Período seco	Abril a junho
		Repouso e senescência dos ramos		Julho a agosto

Fonte: CIIAGRO, 2024; CONAB, 2024.

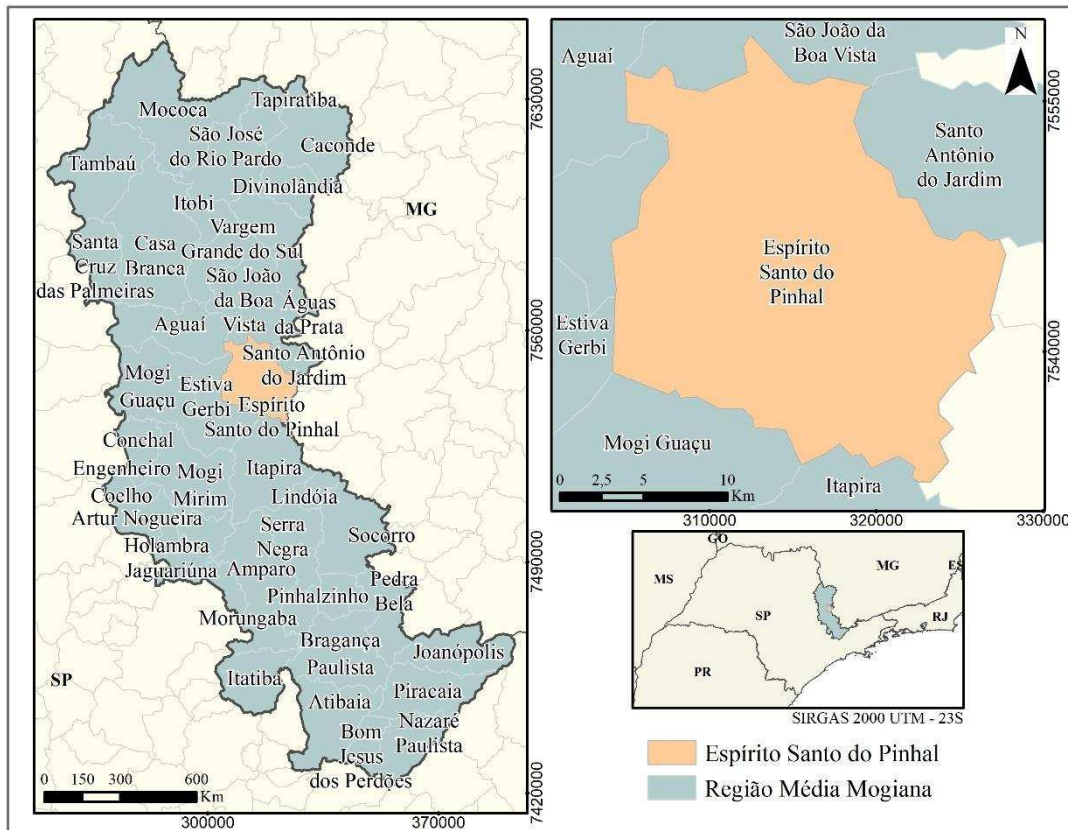
3 Área de Estudo

A pesquisa comparou o resultado da classificação de duas áreas de estudo: Região Média Mogiana e Espírito Santo do Pinhal. A diferença de escala (regional e municipal) foi utilizada como referência para entender a aplicabilidade da metodologia. A Figura 3 ilustra as características de cada área e a Figura 4 mostra a localização das áreas de estudo.

Figura 3 – Características das áreas de estudo

Área de estudo 1	Região Média Mogiana	Localizada no estado de São Paulo, inclui 45 municípios do nordeste paulista. Área total: 13.598,56 km².	Escala de trabalho 1:2.000.000
Área de estudo 2	Município de Espírito Santo do Pinhal	Um dos municípios da Região Média Mogiana. Área total: 390,72 km².	Escala de trabalho 1:200.000

Fonte: Dados IBGE, 2022.

Figura 4 – Mapa da Região Média Mogiana e do Município de Espírito Santo do Pinhal

Fonte: Dados IBGE, 2022.

Segundo o Mapa de Aptidão Agrícola do Estado de São Paulo (CIIAGRO, 2024), as áreas de estudo estão na faixa considerada apta ao cultivo por apresentar condições térmicas e hídricas satisfatórias. As médias de temperaturas anuais variam entre 18°C e 24°C e há concentração de chuvas entre outubro e março, favorecendo o desenvolvimento da planta (CIIAGRO, 2024). Outro fator que contribui para esse cultivo são as altitudes elevadas, que favorecem o desenvolvimento do café, tornando-o produtivo e de alta qualidade (Camargo; Camargo, 2001).

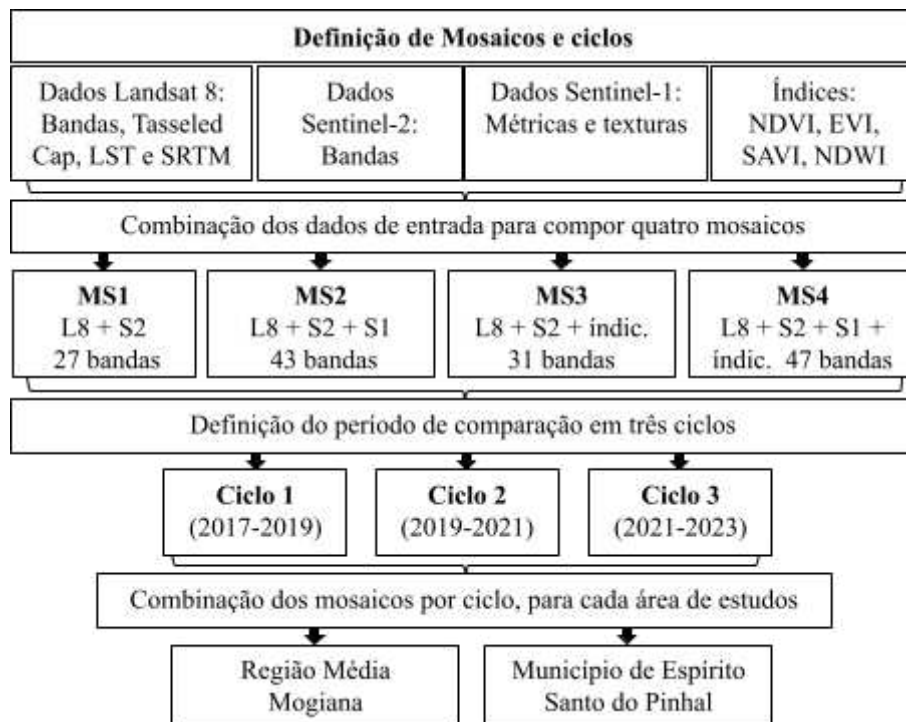
O Mapa Geomorfológico do estado de São Paulo (Ross; Moroz, 1993) mostra que a Média Mogiana está localizada no Planalto Atlântico, com altitudes que variam entre 700 e 1300. Espírito Santo do Pinhal está localizado na transição de duas unidades morfoesculturais: Depressão Periférica e Planalto Atlântico, variando entre topos tabulares (Depressão Mogi-Guaçu) e altitudes mais elevadas (Planalto Atlântico). Na Média Mogiana há concentração de Argissolos e Latossolos (Oliveira et al., 1999), que são dois dos principais tipos de solos utilizados no cultivo de café no Brasil. Enquanto no município predominam duas variações: Argissolos Vermelhos e Argissolos Vermelho-Amarelos (EMBRAPA, 2024).

4 Materiais e Métodos

As principais referências metodológicas da pesquisa foram: Cordero-Sancho; Sader (2007), que combinaram análise multiespectral de imagens Landsat, modelo topográfico e NDVI para melhorar a exatidão de mapeamentos de café; Kawakubo; Perez Machado (2016), que integraram a análise multiespectral e mineração de dados para a distinção de classes cafeeiras; Chemura; Mutanga (2017), que mapearam o café Arábica com imagens multitemporais Landsat 8, associadas à índices de vegetação e o classificador Random Forest (RF); Martello et al. (2022), que utilizaram séries temporais, multiespectrais e o classificador RF para avaliar a produtividade e discutir os estágios fenológicos da cultura de café; Hunt et al. (2020), que elaboraram uma revisão dos métodos de sensoriamento remoto para mapear a produção de café; Kelley; Pitcher, Bacon (2018), que realizaram o mapeamento do café sombreado com GEE; e Maskell et al. (2021), que integraram dados ópticos Sentinel-2 e de radar Sentinel-1 para mapear a produção de café de pequenos produtores com o uso do GEE.

As principais etapas da pesquisa foram ilustradas em dois diagramas (Figuras 5 e 6). A Figura 5 mostra o fluxograma com as etapas metodológicas iniciais, nas quais foram definidas a composição dos mosaicos de imagens de satélite e os ciclos temporais, baseados na fenologia do cafeeiro.

Figura 5 – Fluxograma da definição dos mosaicos e dos ciclos



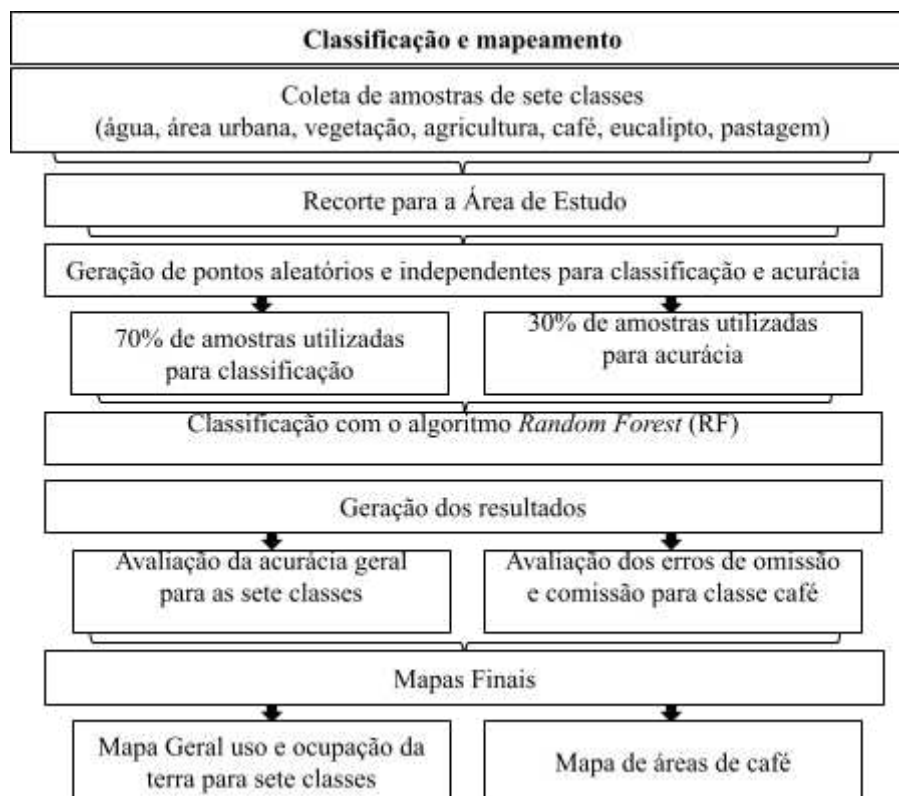
Fonte: Autoria Própria

Os pré-processamentos de cada mosaico incluíram: filtragem de imagens, aplicação de máscara e filtro de nuvem (menor que 10%), correções radiométricas e atmosféricas, cálculo da mediana para fusão das imagens e reamostragem das bandas do Landsat 8 (L8) e das bandas de 20 metros do satélite Sentinel 2 (S2): B5, B6, B7, B8A, B11 e B12, com interpolação bilinear para a resolução de 10 metros. Os índices de vegetação foram gerados com as bandas do L8.

Os mosaicos foram elaborados considerando as particularidades bienais do café Arábica, com a composição de dados das imagens L8 (Manoel; Rosa; Queiroz, 2024), acrescidos por dados S2 e S1, além de índices de vegetação. As métricas da fusão de imagens dos mosaicos foi feita com o cálculo da mediana (Hunt et al., 2020). Os mosaicos foram intitulados: MS1, MS2, MS3 e MS4.

Além das bandas espectrais do L8 (*USGS Landsat 8 Collection 2 Tier 1 TOA Reflectance*), foram incluídas as bandas extraídas da transformação linear de *Kauth-Tomas* (KT), ou método Tasseled Cap, para integrar as características físicas da cena (Kelley; Pitcher; Bacon, 2018). Esse método ajudou a realçar as características da imagem, gerando três componentes básicos: *Brightness*, que representa a quantidade de luz refletida pela superfície; *Greenness*, que representa a reflexão de áreas vegetadas em detrimento das não vegetadas; e *Wetness*, que representa a umidade na superfície (Kauth; Thomas, 1976). A coleção TOA Reflectance é a mais adequada ao uso desse método, contudo são necessárias correções atmosféricas, devido às interferências de ruídos da atmosfera, como os aerossóis (Kelley; Pitcher; Bacon, 2018). Por essa razão, a banda B1 não foi incluída nos mosaicos. A Figura 6 mostra o fluxograma dos procedimentos de classificação e mapeamento.

Figura 6 – Fluxograma da classificação e mapeamento



Fonte: Autoria Própria

Para a classificação, foram coletadas amostras de sete classes de uso da terra: água, área urbana, vegetação, agricultura, café, eucalipto e pastagem. Parte das amostras foi coletada em campo e outras foram criadas pela interpretação visual de imagens de alta resolução, na plataforma Google Earth Pro (Martello et al., 2022). Optou-se pela classificação supervisionada baseada em pixel, por ser uma abordagem simples e eficaz para classificar um número limitado de classes bem definidas. Quando as amostras de treinamento são representativas, essa abordagem pode resultar em uma classificação precisa, especialmente em áreas homogêneas (Hunt et al., 2020). Os polígonos das amostras coletadas foram divididos em: 70% para os pontos aleatórios de treinamento e 30% para os pontos aleatórios de validação, garantindo assim a independência entre ambos.

O classificador utilizado foi o Random Forest (RF), que apresentou boa precisão ao diferenciar áreas de vegetação e outros sistemas de cultivo de áreas de plantio de café (Chemura; Mutanga, 2017; Kelley; Pitcher; Bacon, 2018; Martello et al., 2022). Para validar a acurácia e medir a precisão, adotou-se o modelo de Olofsson et al. (2014). A acurácia foi analisada de duas formas: 1) Acertos do mapeamento para todas as classes (acurácia global) e 2) Erros da classe café: comissão (acurácia do usuário) e omissão (acurácia do

produtor). Por fim, foram gerados os mapas com os usos e ocupações gerais e com áreas de café, para cada área de estudo.

Foram também incluídos os dados de *Land Surface Temperature* (LST), que captam a radiação térmica emitida pela superfície terrestre e ajudam a detectar as diferenças sutis na densidade das folhas e da copa, na morfologia, na biomassa, na composição de espécies e na situação hídrica do dossel em cafezais (Cordero-Sancho; Sader, 2007; Ortega-Huerta et al., 2011; Mukashema; Veldkamp; Vrieling, 2014; Kelley; Pitcher; Bacon, 2018). A metodologia de Ermida et al. (2020), assim como os algoritmos compartilhados, foram usados para criar os dados LST derivados do L8 das áreas de estudo. Foram incluídos também dados do *Shuttle Radar Topography Mission* (SRTM), uma vez que as informações topográficas e a avaliação do relevo são importantes no mapeamento de café (Kelley; Pitcher; Bacon, 2018; Maskell et al. 2021).

Os dados utilizados do satélite Landsat 8 foram:

- Bandas L8: B2 (azul), B3 (verde), B4 (vermelho), B5 (Infravermelho Próximo - NIR), B6 (Infravermelho de Ondas Curtas - SWIR), B7 (Infravermelho de Ondas Curtas - SWIR 2), B8 (Pancromática), B9 (Cirrus), B10 (Infravermelho Termal - TIRS) e B11 (Infravermelho Termal - TIRS 2) – 10 bandas;
- Bandas Tasseled Cap: Brightness, Greenness, Wetness - 3 bandas;
- LST – LST - 1 banda;
- SRTM - Elevação, Inclinação, Aspecto – 3 bandas.

Os dados usados do satélite Sentinel 2 foram:

- Bandas S2: B2 (azul), B3 (verde), B4 (vermelho), B5 (Red Edge 1), B6 (Red Edge 2), B7 ((Red Edge 3), B8 (Infravermelho Próximo - NIR), B8A (Infravermelho Próximo - NIR), B11 (Infravermelho de Ondas Curtas - SWIR), B12 (Infravermelho de Ondas Curtas - SWIR 2) – 10 bandas

Foram utilizadas as bandas espectrais (*Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A*), que tem potencial de melhorar a precisão das classificações (Chaves; Picoli; Sanches, 2020). Essa coleção foi escolhida pela disponibilidade de imagens e menor concentração de nuvens das áreas de estudo. As bandas B1 (Aerossóis), B9 (Vapor de água) e B10 (Cirrus), com resolução espacial de 60 metros, não foram incluídas nos mosaicos devido ao acréscimo de ruídos.

O S2, em comparação à L8, possui uma capacidade espectral que amplia as possibilidades de classificação relacionadas à vegetação, já que possui três bandas Red Edge e duas no Infravermelho Próximo (NIR). A separabilidade dos recursos dessas bandas, está associado tanto à estrutura foliar, como ao conteúdo de clorofila de diferentes espécies de vegetação, o que é adequado para classificar as paisagens heterogêneas (Chaves; Picoli; Sanches, 2020; Hunt et al., 2020). A banda Red Edge 1 (B5) está associada ao teor de clorofila e a Red Edge 3 (B7), assim como a NIR (B8A), estão relacionadas às variações na estrutura da folha. As bandas Infravermelho de Ondas Curtas (SWIR), tanto do L8 como do S2, são relevantes na diferenciação do café das outras vegetações perenes (Hunt et al., 2020; Maskell et al., 2021).

Os dados utilizados do satélite Sentinel 1 foram:

- Polarizações VV VH (descendente e ascendente) – 4 bandas;
- Percentis VV e VH (75% e 25%) – 4 bandas;
- Texturas (GLCM) - Energia, homogeneidade, contraste, correlação, variação, entropia, variância do pixel e sentido – 8 bandas.

Do S1 (*Sentinel-1 SAR GRD: C-band Synthetic Aperture Radar Ground Range Detected*), foram obtidas as métricas e as texturas (Maskell et al., 2021). Informações de órbita ascendente, descendente, polarizações VV e VH, com métricas de medianas, desvio padrão e percentis de 75% e 25% foram incluídos como bandas (Numbisi; Coillie; Wulf, 2019). As texturas foram extraídas por *Gray Level Co-occurrence Matrix* (GLCM) (Maskell et al., 2021). Esses dados são capazes de avaliar as texturas, rugosidades e diferenciar a homogeneidade da paisagem, que contribui para distinguir os tipos de plantios de outras espécies da vegetação (Numbisi; Coillie; Wulf, 2019).

Os índices de vegetação utilizados foram:

- $NDVI = (B5 - B4) / (B5 + B4)$ – 1 banda;
- $EVI = 2,5 * ((B5 - B4) / (B5 + 6 * B4 - 7,5 * B2 + 1))$ – 1 banda;
- $SAVI = ((B5 - B4) / (B5 + B4 + 0,5)) * (1 + 0,5)$ – 1 banda;
- $NDWI = (B5 - B6) / (B5 + B6)$ – 1 banda.

A inclusão de índices variados de vegetação indicou melhorias na classificação do uso da terra e do café (Cordero-Sancho; Sader, 2007; Chemura; Mutanga, 2017; Chemura et al., 2018; Kelley; Pitcher; Bacon, 2018; Hunt et al., 2020; Maskell et al., 2021). Essa combinação de índices aprimorou os resultados da classificação de uso e ocupação de áreas agrícolas (Chaves; Picoli; Sanches, 2020).

Os mosaicos foram reunidos em quatro grupos: 1) MS1 (L8, S2); 2) MS2 (L8, S2, S1); 3) MS3 (L8, S2 e Índices de vegetação) e 4) MS4 (L8, S2, S1 e Índices de vegetação). Esses mosaicos foram comparados nos três ciclos, que refletem os períodos de desenvolvimento do cafeeiro, cuja fase de produção começa em setembro e termina em agosto. Por fim, os mosaicos e os ciclos foram avaliados nas áreas de estudo, região Média Mogiana e o município de Espírito Santo do Pinhal.

Séries de imagens multitemporais foram usadas nos mosaicos, pois apresentaram maior eficácia em classificação de cafezais (Lamparelli et al., 2011; Ortega-Huerta et al., 2011). A Tabela 1 mostra o número de imagens L8, S2 e S1 utilizadas por ciclo, para cada área de estudo. Nas condições especificadas, em ambos os casos, o período do ciclo 2, teve a maior disponibilidade de imagens, e o ciclo 1, a menor disponibilidade.

Tabela 1 - Composição das imagens das áreas de estudo

Média Mogiana	L8	S2	S1	Total	E.S. Pinhal	L8	S2	S1	Total
Ciclo 1	68	376	358	802	Ciclo 1	51	90	120	261
Ciclo 2	59	1007	359	1425	Ciclo 2	40	245	120	405
Ciclo 3	54	834	187	1075	Ciclo 3	19	196	61	276
Total	181	2217	904		Total	110	531	301	

Fonte: Autoria Própria

Os códigos desenvolvidos na pesquisa, com os mosaicos, seleção de amostras e classificação estão disponíveis no GEE, por meio do link: <https://github.com/mariaceciliamanoel>.

5 Resultados e Discussão

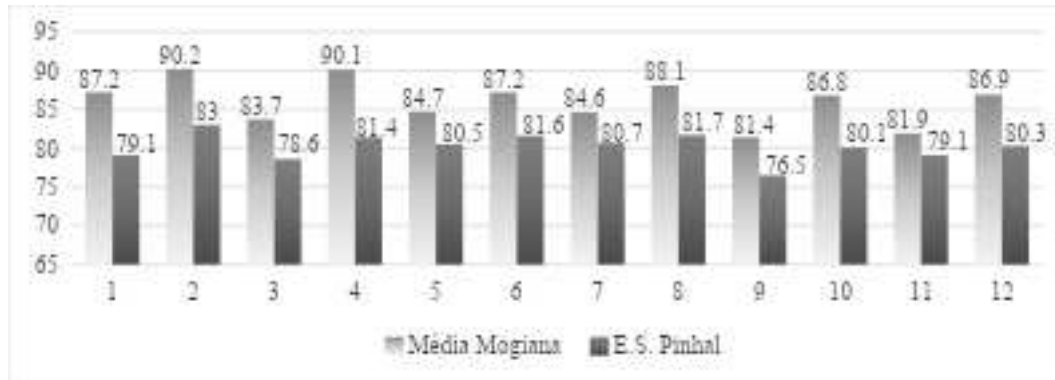
A Tabela 2 mostra os resultados dos acertos para as classes gerais e os erros de omissão e comissão da classe café, em cada mosaico, de cada ciclo. Os erros de comissão estão associados à atribuição errônea de uma classe às áreas onde ela não está presente, ou seja, a classe foi incluída onde não deveria. Enquanto os erros de omissão estão associados à inexatidão em identificar corretamente uma classe em uma área onde ela realmente existe, ou seja, a classe deveria ser mapeada, mas foi omitida.

Tabela 2 – Acurácia global, erros de comissão e erros de omissão, por ciclos, mosaicos e áreas de estudo

Ciclos	Mosaicos	Média Mogiana			E.S. Pinhal		
		Acurácia Global	Erros Comissão – Café	Erros Omissão - Café	Acurácia Global	Erros Comissão – Café	Erros Omissão - Café
Ciclo 1	MS1	87,2	28,9	20,4	79,1	32,3	20,4
	MS2	90,2	25,3	17,2	83	32,4	11,3
	MS3	83,7	35,1	20,8	78,6	33,1	21,4
	MS4	90,1	30,7	18,7	81,4	31,8	11,8
Ciclo 2	MS1	84,7	28,6	24,2	80,5	25,6	8,1
	MS2	87,2	29,1	18,4	81,6	27,4	9
	MS3	84,6	27,6	21,1	80,7	27,8	8,4
	MS4	88,1	28,1	18,4	81,7	29,5	9,3
Ciclo 3	MS1	81,4	30,7	39,6	76,5	31,5	25,5
	MS2	86,8	34,5	21,5	80,1	31,7	14
	MS3	81,9	34,4	38,7	79,1	30,7	20,8
	MS4	86,9	30,7	22,6	80,3	34,2	13,4

Fonte: Autoria Própria

Ao observar a acurácia global dos mosaicos nos três ciclos, é possível constatar que os resultados da Região Média Mogiana foram melhores: o menor acerto foi de 81,4% e o maior acerto foi de 90,2%. Para o município, o menor percentual foi de 76,5% e o maior foi de 83%. Os maiores percentuais de acertos, em ambas as áreas de estudo foram no mosaico MS2, no ciclo 1, assim como os menores foram no MS1, no ciclo 3. A Figura 7 mostra a comparação da acurácia global para as áreas de estudo.

Figura 7 – Acurácia global por ciclos e mosaicos das áreas de estudo

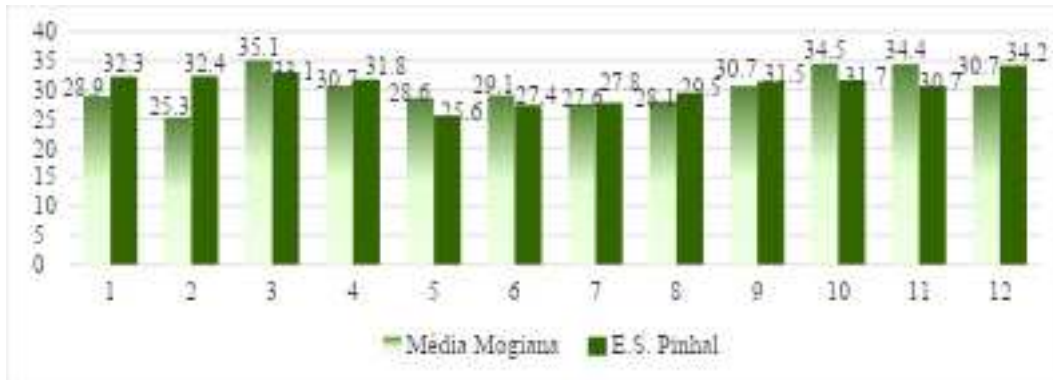
Fonte: Autoria Própria

A resolução espacial tem influência direta na acurácia da classificação, já que pequenos fragmentos podem não ser classificados (Hunt et al., 2020). Essa discussão é importante para a comparação de escalas cartográficas, pois em uma área menor, como é o caso do Município, o modelo tende a acertar menos. Ainda assim, as médias de acertos do município ficaram próximas a 80%, enquanto as médias de acertos da Região Média Mogiana ficaram próximas a 85%.

A aquisição de amostras é uma etapa essencial para uma boa classificação, especialmente das áreas de café (Kelley; Pitcher; Bacon, 2018; Hunt et al., 2020; Maskell et al., 2021). A distribuição, bem como a representatividade de amostras por classe pode interferir diretamente no resultado (Chaves; Picoli; Sanches, 2020; Phiri et al., 2020). No caso da adoção da técnica de aprendizagem por classificação supervisionada, com o classificador RF, o número de amostras, a quantidade de classes e a definição dos parâmetros do classificador para equalizar a atribuição de valores são etapas muito importantes (Chaves; Picoli; Sanches, 2020). Caso haja imprecisões nessas etapas, o classificador pode falhar na discriminação das classes, diminuindo a assertividade da classificação (Hunt et al., 2020; Maskell et al., 2021).

No que se refere à distribuição e à representatividade de amostras, o município teve prioridade, pois possui a menor extensão territorial, de forma a garantir que houvesse amostras de todas as classes. Posteriormente, as amostras foram distribuídas e coletadas em toda a região. Essa etapa foi revista e refeita continuamente, ao longo do processamento, a fim de melhorar o modelo e, consequentemente, aprimorar os resultados da classificação.

Na região da Média Mogiana, os erros de comissão do café se concentraram no ciclo 3, enquanto os menores ocorreram no ciclo 2. As variações tiveram intervalos semelhantes em ambas as áreas de estudo, entre 25,3% e 35% na Média Mogiana e entre 25,6% e 34,2% no município. A Figura 8 mostra a comparação dos erros de comissão.

Figura 8 – Erros de comissão por ciclos e mosaicos das áreas de estudo

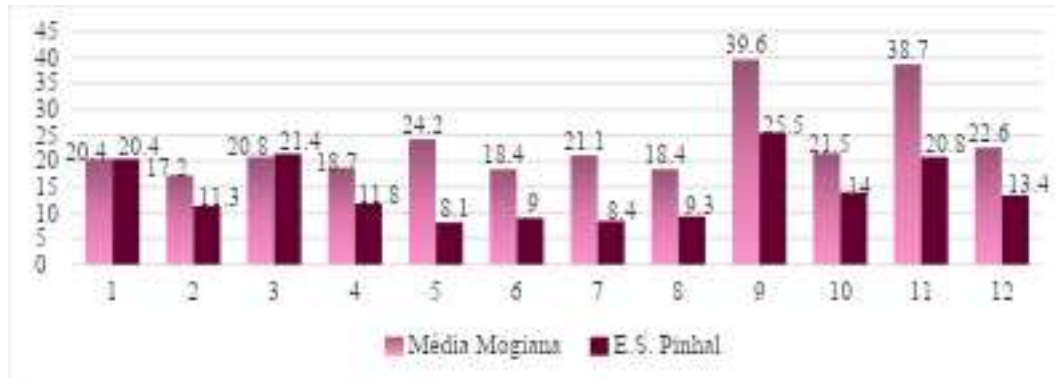
Fonte: Autoria Própria

Quando os erros de comissão são expressivos, há indícios de que há elevada generalização, ou seja, o mapeamento é muito permissivo, com uma tendência a incluir áreas que não pertencem à classe correta (Chaves; Picoli; Sanches, 2020; Hunt et al., 2020). Por exemplo, uma área de vegetação pode incluir erroneamente as áreas de café ou eucalipto, devido a esse nível de generalização. As áreas de transição também tendem a sofrer com os erros de comissão. As áreas de bordas da floresta, onde há a transição da vegetação para áreas de pasto ou de agricultura, podem exemplificar esses erros de comissão (Sun et al., 2019).

As análises estatísticas mostraram que o café teve uma correlação de erro mais próximo à agricultura, revelando a dificuldade do modelo em distinguir essas classes. A diversidade de características da agricultura, principalmente em áreas de cultivos temporários, costuma confundir o classificador, aumentando a ocorrência de erros.

As similaridades espectrais também favorecem esse tipo de erro, assim como a desproporcionalidade do classificador em dar pesos diferentes para algumas classes (Hunt et al., 2020). Isso faz com que o modelo maximize a busca dessas classes, classificando áreas que não correspondem à realidade.

Os erros de omissão apresentaram uma variação maior na Média Mogiana. Os menores erros de omissão foram de 17,2%, no ciclo 1 e, os maiores, de 39,6% no ciclo 3. No município, os menores erros foram de 8,1%, no ciclo 2, e 25,5% no ciclo 3. A Figura 9 representa a distribuição desses erros.

Figura 9 – Erros de omissão por ciclos e mosaicos das áreas de estudo

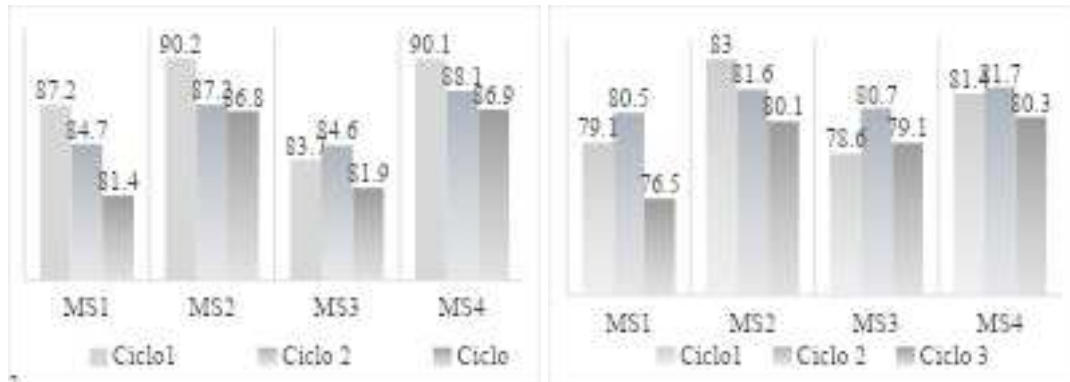
Fonte:

Autoria Própria

Quando os erros de omissão são elevados, há indícios de que o mapeamento está sendo conservador, ou seja, tende a classificar apenas as áreas mais “seguras”, omitindo áreas que são menos evidentes (Chaves; Picoli; Sanches, 2020; Hunt et al., 2020). A falta de representatividade de amostras no modelo pode colaborar para o aumento nos erros de omissão. Classes que apresentam períodos distintos de fases de desenvolvimento ao longo do ano, com variação espectral relevante, como as áreas de plantio, devem ter amostras que considerem espectros variados em diferentes estágios (área recém-plantada, em plena produção, área recém-colhida). Essa observação é válida para o café pois, apesar de ser uma cultura perene, possui uma variação espectral relevante em anos de bienalidade positiva e negativa (Kelley; Pitcher; Bacon, 2018; Maskell et al., 2021; Martello et al., 2022).

Os menores erros de omissão observados no município, em comparação à região, revelam um bom potencial de aplicação do modelo em áreas menores. Isso se deve a à baixa diversidade de tipos de uso e ocupação da terra (Chaves; Picoli; Sanches, 2020). Além disso, a boa qualidade da identificação das outras classes é primordial para melhorar a discriminação da classe alvo, uma vez que a compreensão dos erros de outras classes ajudam a aprimorar o modelo.

Ao comparar os mosaicos, as combinações do MS2 (L8, S2 e S1) e do MS4 (L8, S2, S1 e índices de vegetação), geraram os melhores conjuntos de acurácia global, em ambas as áreas de estudo, nos três ciclos avaliados. Na Média Mogiana, a média de acurácia no MS2 foi de 88% e, no MS4, foi de 88,3%. Em Espírito Santo do Pinhal, a média no MS2 foi de 81,5% e, no MS4, foi de 81,1%. A Figura 10 mostra a acurácia global, considerando os mosaicos avaliados.

Figura 10 – Acurácia global dos mosaicos das áreas de estudo

Fonte:

Autoria Própria

Esses mosaicos demonstram que a inclusão das métricas e texturas do S1, tanto no MS2 quanto no MS4, melhoraram as acurácias. Os dados do S1, embora utilizados na identificação de diversos tipos de cultivos (Sun et al., 2019; Chaves; Picoli; Sanches, 2020), ainda possuem aplicação relativamente recente na classificação de áreas de café (Hunt et al., 2020; Maskell et al., 2021). Além de captar informações sobre a estrutura da planta, sobre o teor de umidade e contribuir para diferenciar a produção de café sombreado das vegetações do entorno, os dados do S1 têm vantagens em relação às condições atmosféricas e de iluminação, permitindo uma coleta de dados temporais constante (Chaves; Picoli; Sanches, 2020). O uso do S1 ainda apresenta ressalvas, pela complexidade do tratamento de dados em relação aos dados ópticos, contudo tem um significativo potencial de evolução do processo de classificação (Sun et al., 2019).


Para a classificação do café e de outras culturas arbóreas esparsas, os dados da banda C do S1, pelo seu menor comprimento de onda (entre 3 e 5 cm), são mais adequados em comparação ao comprimento de onda do Landsat, frequentemente utilizado para mapeamento de uso e ocupação da terra (Maskell et al., 2021).

A combinação L8 e S2, observada nos mosaicos MS1 e MS3, apesar de não representar acréscimos expressivos na acurácia global, em comparação com os mosaicos do L8 (Manoel; Rosa; Queiroz, 2024), foi importante na redução dos erros do café, revelando um potencial importante na diferenciação de classes. A classificação de café de Manoel, Rosa e Queiroz (2024), com o L8, evidenciaram imprecisões associadas às classes de café e vegetação, e de café e eucalipto. A inclusão do S2, reduziu essas divergências, o que pode ser associado às duas bandas NIR, que auxiliaram na diferenciação de reflectância dessas classes (maior na vegetação e menor no eucalipto). As bandas Red Edge, contudo, são os diferenciais mais relevantes do S2, por causa da maior sensibilidade na identificação de clorofila e na diferenciação na estrutura foliar, potencializando a distinção de classes (Chaves; Picoli; Sanches, 2020). Para o café, as características das bandas Red Edge ajudam também na discriminação das áreas de pasto e de outras coberturas vegetais (Maskell et al., 2021).

A inclusão de índices de vegetação, especialmente o NDVI e o NDWI também foram importantes para ajudar na diferenciação dessas classes específicas, já que esses índices apresentam valores mais baixos na classe eucalipto, em comparação à vegetação e ao café. Para futuras classificações, o uso do *Normalized Difference Red Edge* (NDRE), índice semelhante ao NDVI que utiliza as bandas NIR e Red Edge do S2, deve torná-lo mais sensível às variações do teor de clorofila e estresse da planta, e aumentar a eficácia da classificação de uso e ocupação da terra, principalmente em áreas agrícolas (Chaves; Picoli; Sanches, 2020).

A avaliação dos erros de comissão revela que a média na região foi de 30,3%, semelhante ao município, com média de 30,6%. Em ambas as áreas de estudo, os erros mais elevados foram no MS3. Esses resultados mostram que ainda é necessário aprimorar a classificação em todos os mosaicos, pois as áreas cafeeiras estão sendo superestimadas. Uma solução para melhorar esse cenário, já que a correlação de erros do café foi associada à agricultura, seria dividir essa classe entre agricultura temporária e permanente, uma vez que outros cultivos permanentes foram erroneamente classificados como café. A Figura 11 mostra a comparação das duas áreas de estudo, considerando os erros de comissão dos mosaicos.

Figura 11 – Erros de comissão dos mosaicos das áreas de estudo



Fonte:

Autoria Própria

Os erros de omissão apresentaram variações mais expressivas nas áreas de estudo. Na Média Mogiana, o MS2 e o MS4 também se destacaram com os menores erros, com médias próximas a 19% (Figura 12). No MS1 e MS3, os erros foram aproximadamente 30% maiores. No município, a média de erro do MS2 e do MS4 foi de 11,5%, enquanto no MS1 e no MS3 os erros de comissão foram cerca de 34% mais altos.

Figura 12– Comparação dos erros de omissão dos mosaicos das áreas de estudo



Fonte: Autoria Própria

Esses resultados indicam que a combinação L8, S2 e S1, apesar de não ter resultados expressivos nos erros de comissão, melhora significativamente os erros de omissão. A representatividade de amostras de café ao longo do ciclo, considerando a bienalidade e as diferentes fases fenológicas da planta, puderam ser mais bem percebidas pela combinação dos mosaicos MS2 e MS4.

Na comparação dos mosaicos MS2 e MS4 (Tabela 3), os resultados revelaram muita similaridade em relação à assertividade dos resultados. Assim, em futuras classificações, recomenda-se a inclusão de índices de vegetação, sejam os avaliados nesta pesquisa ou outros que possam melhorar a eficácia do modelo.

Tabela 3 – Acurácia global, erros de comissão e erros de omissão, dos mosaicos MS2 e MS4

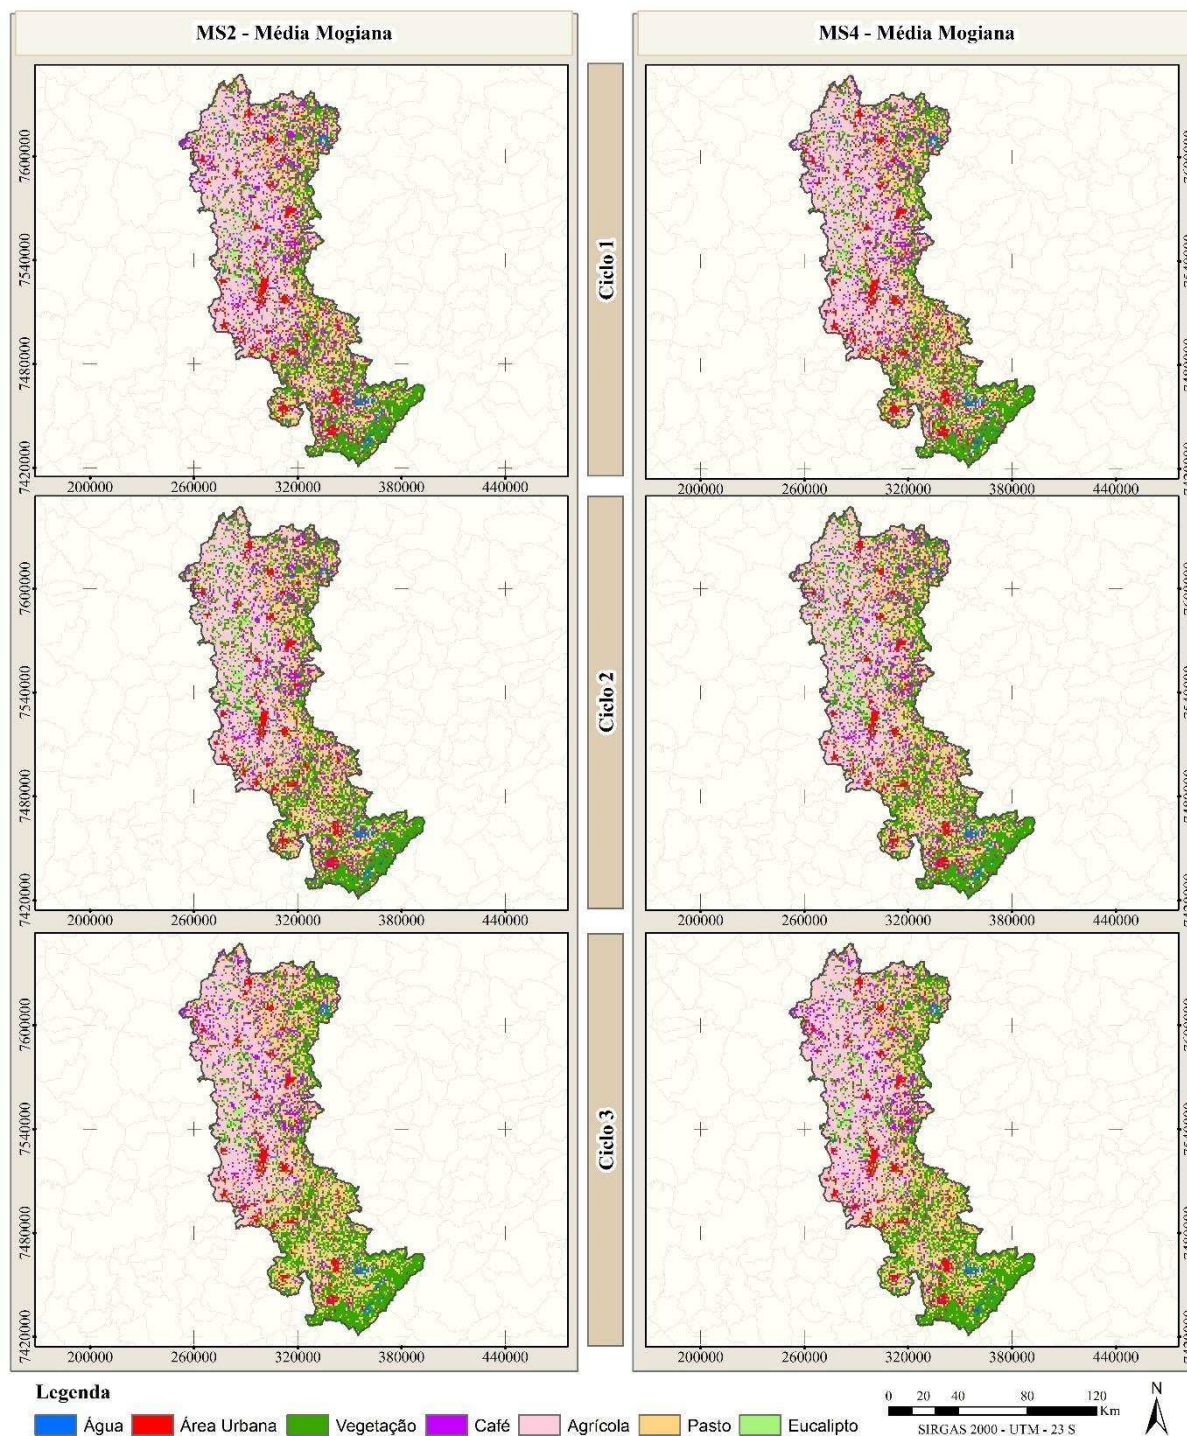
Ciclos	Mosaicos	Região Média Mogiana			Município de Espírito Santo do Pinhal		
		Acurácia Global	Erros de Comissão	Erros de Omissão	Acurácia Global	Erros de Comissão	Erros de Omissão
Ciclo 1	MS2	90,2	25,3	17,2	83	32,4	11,3
	MS4	90,1	30,7	18,7	81,4	31,8	11,8
Ciclo 2	MS2	87,2	29,1	18,4	81,6	27,4	9
	MS4	88,1	28,1	18,4	81,7	29,5	9,3
Ciclo 3	MS2	86,8	34,5	21,5	80,1	31,7	14
	MS4	86,9	30,7	22,6	80,3	34,2	13,4

Fonte: Autoria Própria

O uso do RF mostrou bons resultados. Mas, apesar de ser um classificador robusto, seu desempenho está diretamente associado ao número de amostras de treinamento, classes de cobertura de uso e ocupação, tipo de terreno e pré-processamento de dados (Phiri et al., 2020). Desse modo, recomenda-se que haja equilíbrio entre as classes mapeadas, pois as classes menores ou menos representadas no modelo são mais propensas a erros, pois o algoritmo tende a priorizar as classes dominantes. Os parâmetros de árvore de decisão do RF também precisam ser equalizados para que não haja grandes discrepâncias de uma classe sobre a outra.

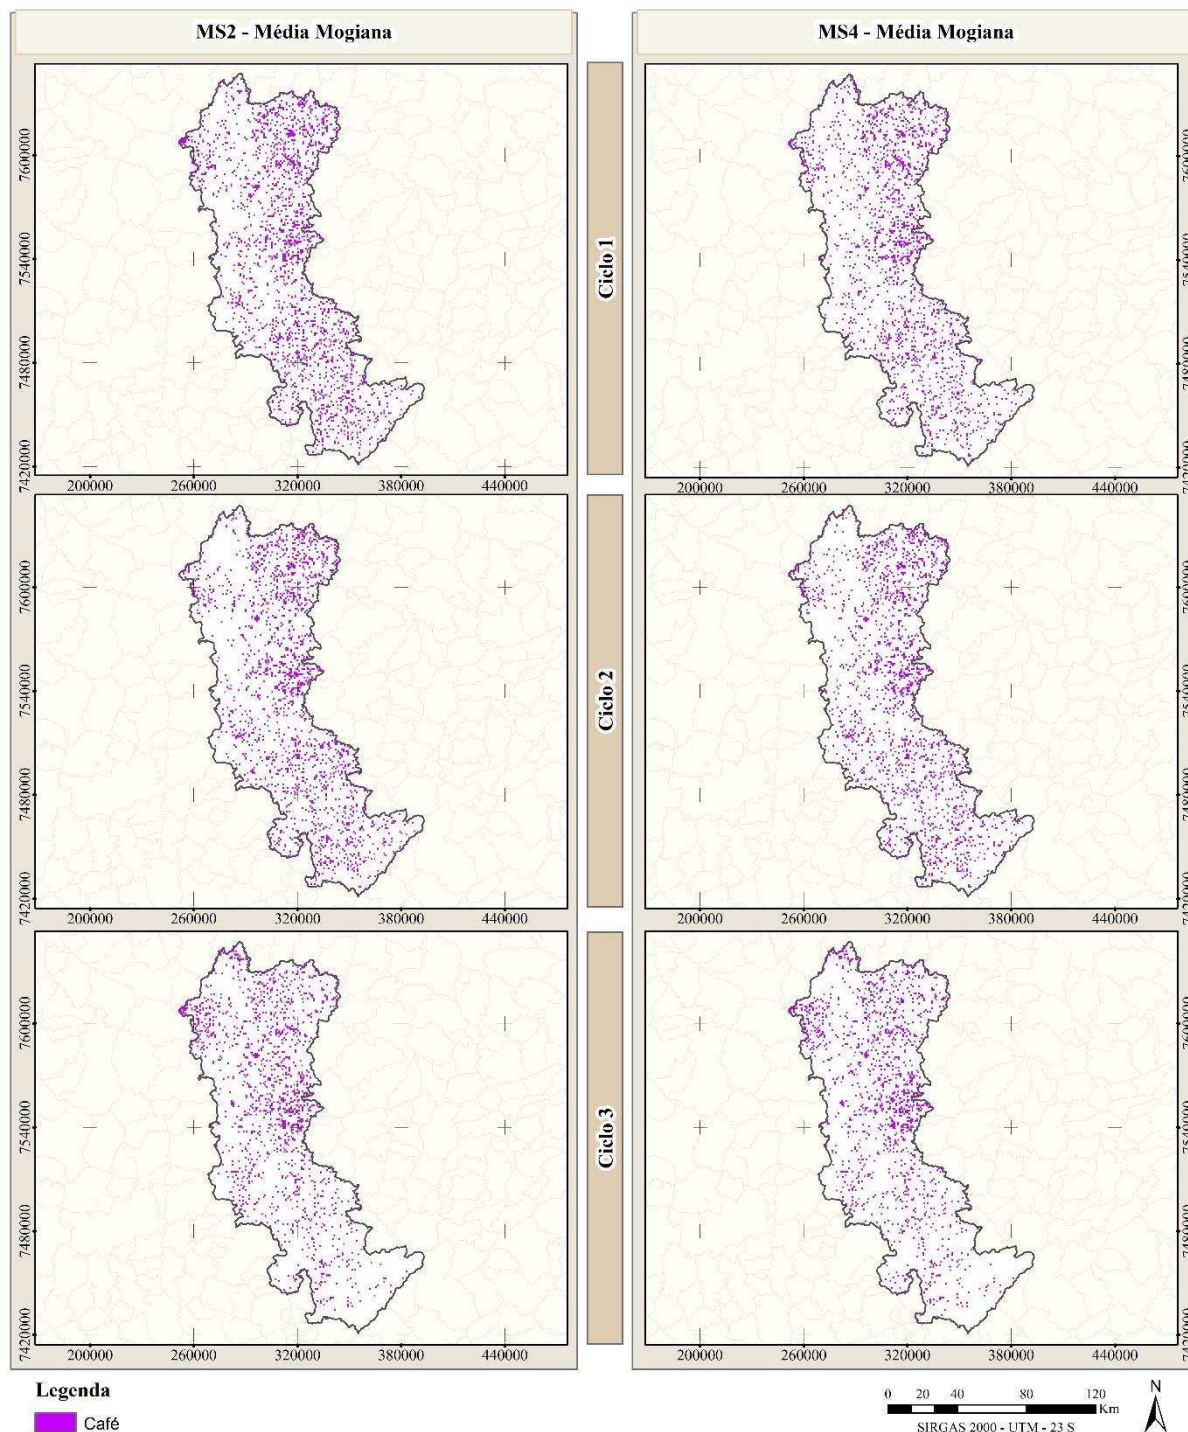
As figuras 13 e 14 mostram as classificações da região Média Mogiana, com resultados dos mosaicos MS2 e MS4, conforme os diferentes ciclos. A Figura 13 ilustra a classificação do uso e ocupação da terra (sete classes) e, a Figura 14, a classificação do café.

Figura 13 – Classificação de uso e ocupação da terra, Média Mogiana, mosaicos MS2 e MS4, por ciclos



Fonte: Autoria Própria

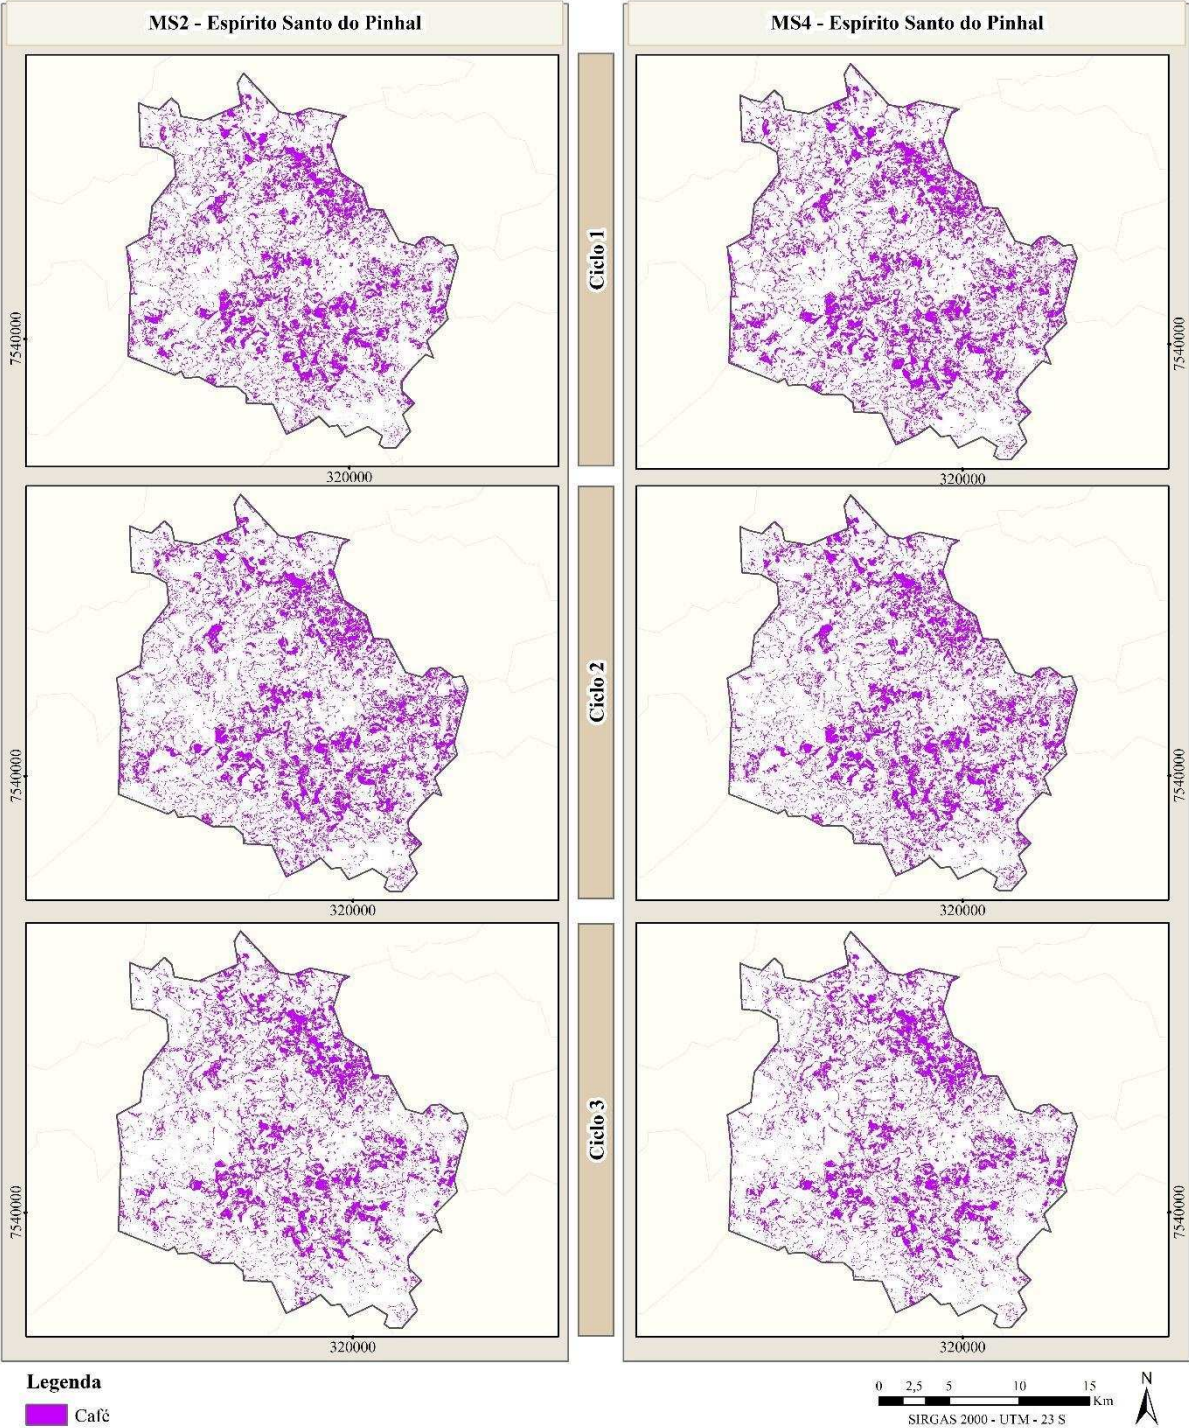
Figura 14 – Classificação do café Árábica na região Média Mogiana, mosaicos MS2 e MS4, por ciclos



Fonte: Autoria Própria

A classificação do município de Espírito Santo do Pinhal revela que os resultados menos expressivos também foram associados ao MS2 e MS4, no ciclo 3 (Figuras 15 e 16). Enquanto o MS2, no ciclo 1, apresentou os melhores resultados em ambas as áreas de estudo.

Figura 16 – Classificação do café Arábica, mosaicos MS2 e MS4 divididos por ciclos



Fonte: Autoria Própria

6 Considerações Finais

A integração de dados L8, S2 e S1 aumentou a acurácia global e reduziu os erros de classificação do café, em média de 23% nos erros de comissão e de 50% nos erros de omissão. Mosaicos com a integração das imagens (MS2) com os índices de vegetação (MS4) destacaram-se de forma semelhante, apresentando grande potencial de melhoria da acurácia da classificação. A metodologia adotada gerou uma classificação de uso e ocupação da terra adequada para as escalas regionais e municipais. A região da Média Mogiana teve uma média 5,85% maior em comparação ao município, no que se refere à acurácia global para todas as classes, atingindo 90,2% (MS2). Os erros de comissão tiveram uma diferença mínima de 0,36%, e os erros de omissão na Média Mogiana foram, em média, 9% maiores. Assim, apesar de o modelo ter uma tendência a ser mais permissivo, omitiu poucas áreas desse cultivo especialmente no município, atingindo acurácia do produtor (associado aos erros de omissão) de 91% (MS2) nas áreas de café.

Para a aplicação dessa metodologia em outras áreas de plantio do café Arábica, considera-se prudente avaliar os ciclos bienais e de desenvolvimento do cultivo para definir os mosaicos multitemporais, compostos de dados multissensores L8, S2, S1 e índices de vegetação. Recomenda-se também a definição das classes de uso e ocupação que considerem as particularidades locais e atenção à coleta de amostras representativas de todas as classes, em todo período avaliado.

Referências Bibliográficas

- ABIC, Associação Brasileira da Indústria de Café. Estatísticas. Disponível em: <https://estatisticas.abic.com.br/>. Acesso em: jan. 2024.
- ADRIAN, Jarrett; SAGAN, Vasit; MAIMAITIJANG, Maitiniyazi. Sentinel SAR-optical fusion for crop type mapping using deep learning and Google Earth Engine. *ISPRS Journal of Photogrammetry and Remote Sensing*. V. 175, 215–235, 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271621000599>. Acesso em: dez. 2024.
- CAMARGO, Ângelo Paes de.; CAMARGO, Marcelo Bento Paes de. Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil. *Bragantia*, V. 60, n. 1, 65–68, 2001.
- CHAVES, Michel E. D.; PICOLI, Michelle C. A.; SANCHES, Ieda D. Recent Applications of Landsat 8/OLI and Sentinel-2/MSI for Land Use and Land Cover Mapping: A Systematic Review. *Remote Sens*. V. 12 (18), 3062, 2020. Disponível em: <https://www.mdpi.com/2072-4292/12/18/3062>. Acesso em: dez. 2024.
- CHEMURA, Abel; MUTANGA, Onesimo. Developing detailed age-specific thematic maps for coffee (*Coffea arabica* L.) in heterogeneous agricultural landscapes using random forests applied on Landsat 8 multispectral sensor. *Geocarto International*, 32: 759–776, 2017. Disponível em: <https://doi.org/10.1080/10106049.2016.1178812>. Acesso em: jan. 2021.
- CHEMURA, Abel; MUTANGA, Onesimo; ODINDI, John; KUTYWAYO, Dumisani. Mapping spatial variability of foliar nitrogen in coffee (*Coffea arabica* L.) plantations with multispectral Sentinel-2 MSI data. *ISPRS Journal of Photogrammetry and Remote Sensing*, V.138, 1–11, 2018. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2018.02.004>. Acesso em: jan. 2021.
- CIIAGRO, Centro Integrado de Informações Agrometeorológicas. Aptidão Ecológica da Cultura do Café. Disponível em: <https://www.ciiagro.sp.gov.br/zoneamento/cafe.htm>. Acesso em: jan. 2024.
- CONAB, Companhia Nacional de Abastecimento. Safra Brasileira de Café. Disponível em: <https://www.conab.gov.br/info-agro/safras/cafe>. Acesso em: jan. 2024.
- CORDERO-SANCHO, S., SADER, S.A. Spectral analysis and classification accuracy of coffee crops using Landsat and a topographic-environmental model. *International Journal of Remote Sensing*, V. 28 (7), 1577–1593, 2007. Disponível em: <https://doi.org/10.1080/01431160600887680>. Acesso em: jan. 2021.
- EMBRAPA, Empresa Brasileira de Pesquisa Agropecuária. Unidade Embrapa Café. Disponível em: <https://www.embrapa.br/cafe>. Acesso em: jan. 2024.
- ERMIDA, Sofia L.; SOARES, Patrícia.; MANTAS, Vasco.; GÖTTSCHE, Frank-M.; TRIGO, Isabel F. Google Earth Engine Open-Source Code for Land Surface Temperature Estimation from the Landsat Series. *Remote Sens*. V.12 (9), 1471, 2020. Disponível em: <https://doi.org/10.3390/rs12091471>. Acesso em: jan. 2023.
- ESCOBAR-LÓPEZ, Agustín; CASTILLO-SANTIAGO, Miguel Ángel; MAS, Jean F.; HERNÁNDEZ-STEFANONI, José Luis; LÓPEZ-MARTÍNEZ, Jorge Omar. Identification of coffee agroforestry systems using remote sensing data: a review of methods and sensor data, *Geocarto International*, V 39:1, 2297555, 2024. Disponível em: <https://doi.org/10.1080/10106049.2023.2297555>. Acesso em: dez. 2024.

HUNT, David A.; TABOR, Karyn; HEWSON, Jennifer H.; WOOD, Margot A.; REYMONDIN, Louis; KOENIG, Kellee; SCHMITT-HARSH, Mikaela; FOLLETT, Forrest. Review of Remote Sensing methods to map coffee production systems. *Remote Sens*, V. 12 (18), 2041, 2020. Disponível em: <https://www.mdpi.com/2072-4292/12/12/2041>. Acesso em: jan. 2023.

IBGE, Instituto Brasileiro de Geografia e Estatística. IBGE Cidades. Disponível em: <https://cidades.ibge.gov.br/>. Acesso em: abril 2022.

IOC, International Coffee Organization. Coffee Market Report. Disponível em: <https://ico.org/#>. Acesso em: jan. 2024.

KAUTH, R.J.; THOMAS, G.S. The Tasseled Cap—A graphic description of the spectral-temporal development of agricultural crops as seen by Landsat. In *LARS symposia*, p. 159, 1976.

KAWAKUBO, Fernando Shinji; PEREZ MACHADO, Reinaldo Paul. Mapping coffee crops in southeastern Brazil using spectral mixture analysis and data mining classification. *International Journal of Remote Sensing*, V. 37, 14, 3414–3436. 2016. Disponível em: <https://doi.org/10.1080/01431161.2016.1201226>. Acesso em: jan. 2021.

KELLEY, Lisa C.; PITCHER, Lincoln; BACON, Chris. Using Google Earth Engine to Map Complex Shade-Grown Coffee Landscapes in Northern Nicaragua. *Remote Sens*, 10 (16) 952, 2018. Disponível em: <https://www.mdpi.com/2072-4292/10/6/952>. Acesso em: jan. 2021.

LAMPARELLI, Rubens A C; NERY, Luiz; ROCHA; JANSLE, V. Coffee crop mapping using principal component analysis and illumination factor for complex relief. *Topografia, Fotogrametria e Sensoriamento Remoto, Engenharia Agrícola*, V.31 (3), 2011. Disponível em: <https://doi.org/10.1590/S0100-69162011000300018>. Acesso em: jan. 2023.

MALAVOLTA, E.; HAAG, H. P.; MELLO, F. A. F.; BRASIL SOBRINHO, M. O. C. Nutrição mineral e adubação do cafeeiro. Nutrição mineral e adubação de plantas cultivadas. São Paulo: Pioneira, 1974.

MANOEL, Maria Cecilia; ROSA, Marcos Reis; QUEIROZ, Alfredo Pereira de. Analysis of the Biennial Productivity of Arabica Coffee with Google Earth Engine in the Northeast Region of São Paulo, Brazil. *Remote Sens*, V.16(20), 3833. 2024. Disponível em: <https://doi.org/10.3390/rs16203833>. Acesso em: jan. 2025.

MARTELLO, Maurício; MOLIN, José Paulo; WEI, Marcelo Chan Fu; CANAL FILHO, Ricardo; NICOLETTI, João Vitor Moreira. Coffee-Yield Estimation Using High-Resolution Time-Series Satellite Images and Machine Learning. *AgriEngineering*, V. 4(4), 888-902, 2022. Disponível em: <https://doi.org/10.3390/agriengineering4040057>. Acesso em: dez. 2024.

MARTINS, Roberto Vasconcelos. Divino Espírito Santo e Nossa Senhora das Dores do Pinhal – História de Espírito Santo do Pinhal. Ribeirão Preto: Impressora Latina Ltda, 1986.

MASKELL, Gina; CHEMURA, Abel; NGUYEN, Huong; GORNOTT, Christoph; MONDAL, Pinki. Integration of Sentinel optical and radar data for mapping smallholder coffee production systems in Vietnam. *Remote Sensing of Environment*, V. 266, 112709, 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0034425721004296>. Acesso em: dez. 2021.

MOREIRA, Cassio Franco. Sustentabilidade de sistemas de produção de café sombreado orgânico e convencional. Tese de Doutorado - Ecologia Aplicada, Universidade de São Paulo, Piracicaba, 2009. Disponível em: <https://doi.org/10.11606/T.91.2009.tde-22052009-151446>. Acesso em: jan. 2021.

MUKASHEMA, A.; VELDKAMP, Antonie; VRIELING, Anton. Automated high resolution mapping of coffee in Rwanda using an expert Bayesian network. V. 33(1), 331–340, 2014. Acesso em: jan. 2021.

NUMBISI, Frederick N.; COILLIE, Fieke M. B. Van; WULF, Robert De. Delineation of Cocoa Agroforests Using Multiseason Sentinel-1 SAR Images: A Low Grey Level Range Reduces Uncertainties in GLCM Texture-Based Mapping. ISPRS Int. J. Geo-Inf. V.8(4), 179, 2019. Disponível em: <https://www.mdpi.com/2220-9964/8/4/179>. Acesso em: dez. 2024. <https://doi.org/10.3390/ijgi8040179>

OLIVEIRA, J.; CAMARGO, M.; ROSSI, M.; CALDERANO FILHO, B. Mapa Pedológico do Estado de São Paulo. Congresso Brasileiro de Ciência do Solo- Brasília, 27, 1999.

OLOFSSON, P.; FOODY, G.M.; HEROLD, M.; STEHMAN, S.V.; WOODCOCK, C.E.; WULDER, M.A. Good practices for estimating area and assessing the accuracy of land change. Remote Sensing of Environment, V. 148, 42–57, 2014.

ORTEGA-HUERTA, Miguel Alfonso; KOMAR, Oliver; PRICE, Kevin; VENTURA Hugo J. Mapping coffee plantations with Landsat imagery: an example from El Salvador. International Journal of Remote Sensing, V. 33(1), 220–242. 2011. Disponível em: <https://doi.org/10.1080/01431161.2011.591442>. Acesso em: jan. 2021.

PEREIRA, Antônio Roberto; ANGELOCCI, Luiz Roberto; SENTELHAS, Paulo César. Agrometeorologia: Fundamentos e aplicações práticas. Guaíba: Agropecuária, 2002.

PHIRI, Darius; SIMWANDA, Matamy; SALEKIN, Serajis; NYIRENDA, Vincent R.; MURAYAMA, Yuji; RANAGALAGE, Manjula. Sentinel-2 Data for Land Cover/Use Mapping: A Review. Remote Sens. V. 12(14), 2291, 2020. Disponível em: <https://www.mdpi.com/2072-4292/12/14/2291>. Acesso em: dez. 2024.

ROSS, Jurandyr Luciano Sanches; MOROZ, Isabel Cristina. Mapa Geomorfológico do estado de São Paulo. Revista do Departamento de Geografia, V.10, 1996. Disponível em: <https://doi.org/10.7154/RDG.1996.0010.0004>. Acesso em: jan. 2021.


SUN, Chuanliang; BIAN, Yan; ZHOU, Tao; PAN, Jianjun. Using of Multi-Source and Multi-Temporal Remote Sensing Data Improves Crop-Type Mapping in the Subtropical Agriculture Region. Sensors, V. 19 (10), 2401, 2019. Disponível em: <https://www.mdpi.com/1424-8220/19/10/2401>. Acesso em: dez. 2024.

TAMIMINIA, Haifa; SALEHI, Bahram; MAHDIANPARI, Masoud; QUACKENBUSH, Lindi; ADELI, Sarina; BRISCO, Brian. Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. ISPRS Journal of Photogrammetry and Remote Sensing. V. 164, 152-170, 2020. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2020.04.001>. Acesso em: dez. 2024.


SOBRE OS AUTORES

Maria Cecília Manoel  - Geógrafa, Mestre em Geografia Humana, Doutoranda no Programa de Pós Graduação de Geografia Física – USP.

E-mail: maria.manoel@usp.br

Alfredo Pereira de Queiroz  - Geógrafo, Professor Titular, Departamento de Geografia FFLCH - USP.

E-mail: aqueiroz@usp.br

Marcos Reis Rosa  - Geógrafo, Doutor em Geografia Física, Professor Convidado do Programa de Pós Graduação de Geografia Física – USP.

E-mail: mrosa@arcplan.com.br

Data de submissão: 27 de março de 2025

Aceito para publicação: 16 de abril de 2025

Data de publicação: 14 de maio de 2025