



KELVIN RIBEIRO DE SOUZA

**SÉRIE TEMPORAL NO MAPEAMENTO DE ÁREAS
CAFEEIRAS DO SUL DE MINAS GERAIS**

**LAVRAS - MG
2024**

KELVIN RIBEIRO DE SOUZA

**SÉRIE TEMPORAL NO MAPEAMENTO DE ÁREAS CAFEEIRAS DO SUL DE
MINAS GERAIS**

Monografia apresentado à Universidade Federal de Lavras, como parte das exigências do Curso de Graduação em Engenharia Florestal, para a obtenção do título de Bacharel.

Prof. Dr. Fausto Weimar Acerbi Júnior
Orientador

**LAVRAS – MG
2024**

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

Souza, Kelvin Ribeiro de.

Série temporal no mapeamento de áreas cafeeiras do sul de
minas gerais / Kelvin Ribeiro de Souza. - 2024.

41 p. : il.

Orientador(a): Fausto Weimar Acerbi Júnior.

TCC (graduação) - Universidade Federal de Lavras, 2024.

Bibliografia.

1. Geoprocessamento. 2. Café. 3. Supervisionada. I. Acerbi
Júnior, Fausto Weimar. II. Da Pascoa, Kalill Jose Viana. III. Meireles,
Thiago Magalhães. IV. Título.

KELVIN RIBEIRO DE SOUZA

**SÉRIE TEMPORAL NO MAPEAMENTO DE ÁREAS CAFEEIRAS DO
SUL DE MINAS GERAIS**

**TEMPORAL SERIES IN THE MAPPING OF COFFEE-GROWING AREAS IN
THE SOUTHERN REGION OF MINAS GERAIS.**

Monografia apresentado à Universidade Federal de Lavras, como parte das exigências do Curso de Graduação em Engenharia Florestal, para a obtenção do título de Bacharel.

APROVADO EM 25 DE MARÇO DE 2024

Prof. Dr. Fausto Weimar Acerbi Júnior, UFLA

Dr. Kalill Jose Viana da Pascoa, UFLA

Ms. Thiago Magalhães Meireles, UFLA

Prof. Dr. Fausto Weimar Acerbi Júnior
(Orientador)

**LAVRAS – MG
2024**

AGRADECIMENTOS

Agradeço aos meus pais Eugênio Claudio de Souza e Maria Auxiliadora Ribeiro de Souza por todo apoio fornecido ao longo da minha formação. Aos meus irmãos Wesley Ribeiro de Souza e Jéssika Ribeiro de Souza e minha namorada Ana Vitória Niz Gomes da Silva por me ajudarem nessa caminhada.

À Universidade Federal de Lavras (UFLA) por todo conhecimento e subsídio para o desenvolvimento da minha vida pessoal e profissional, em especial ao corpo docente e funcionários do departamento de ciências florestais (DCF).

Aos amigos do Brejão, em especial aos moradores do 310, pelos ensinamentos ao longo dos anos, parcerias e trocas.

Ao meu orientador Prof. Dr. Fausto Weimar Acerbi Júnior e minha banca Kalill Jose Viana da Páscoa e Thiago Magalhães Meireles, por toda orientação e paciência durante o desenvolvimento da minha formação e disponibilidade em todos os momentos.

RESUMO

O Brasil é líder mundial na produção de café, com destaque para os estados como Minas Gerais, São Paulo e Paraná contribuindo significativamente. Diante do aumento da ocorrência de eventos climáticos, como as geadas de 2021, que afetaram negativamente a produção, o monitoramento das áreas de cultivo é vital para os produtores. Este estudo visa mapear as áreas de cultivo de café na região sul de Minas Gerais e avaliar os impactos das geadas ocorridas em 2021. Os objetivos específicos incluem avaliar mudanças nas áreas entre 2019 e 2023, realizar classificação com imagens Sentinel-2A MSI, comparar classificações e testar a eficácia do pós-processamento. A classificação supervisionada foi realizada no software *Semi-Automatic Classification Plugin* e as amostras de treinamento (ROI) de cada classe da cobertura do solo foram coletadas aleatoriamente. Três algoritmos foram aplicados durante o processo de classificação das imagens: Máxima Verossimilhança, Mínima Distância e Spectral Angle Mapper. Na etapa de pós-processamento utilizou-se o filtro “*majority*” com o intuito de melhorar a classificação. Os resultados mostraram um aumento significativo na área de cultivo de café na região. A classe “Café” teve um aumento de 46,10% entre 2019 e 2023, destacando o Sul de Minas como um importante polo produtor. O algoritmo de Máxima Verossimilhança mostrou-se mais eficaz na classificação com valores de acurácia global em torno de 81,91% em 2019 e 91,54% em 2023. O software *Semi-automatic Classification* foi útil para mapeamentos em larga escala, enquanto o filtro majoritário melhorou a acurácia da classificação. A semelhança espectral entre as classes de Café e Florestas apresentou desafios, destacando a importância da validação em campo e do uso de técnicas como o Sistema de Análise Temporal da Vegetação, o SATVeg, para facilitar a distinção entre classes.

Palavras-chave: Geoprocessamento, Sentinel-2A MSI, Café, Classificação supervisionada, Geadas.

ABSTRACT

Brazil is the world leader in coffee production, with states such as Minas Gerais, São Paulo and Paraná contributing significantly. Given the increase in the occurrence of climatic events, such as the 2021 frosts, which negatively affected production, monitoring cultivation areas is vital for producers. This study aims to map the coffee growing areas in the southern region of Minas Gerais. Specific objectives include evaluating changes in areas between 2019 and 2023, performing classification with Sentinel-2A MSI images, comparing classifications, and testing the effectiveness of post-processing. Supervised classification was performed using the Semi-Automatic Classification Plugin software and training samples (ROI) for each land cover class were randomly collected. Three algorithms were applied during the image classification process: Maximum Likelihood, Minimum Distance and Spectral Angle Mapper. In the post-processing stage, the “majority” filter was used in order to improve the classification. The results showed a significant increase in the coffee cultivation area in the region. The “Café” class increased by 46.10% between 2019 and 2023, highlighting the South of Minas as an important producing hub. The Maximum Likelihood algorithm proved to be more effective in classification with global accuracy values of around 81.91% in 2019 and 91.54% in 2023. The Semi-automatic Classification software was useful for large-scale mapping, while the Majority filter improved classification accuracy. The spectral similarity between the Coffee and Forest classes presented challenges, highlighting the importance of field validation and the use of techniques such as the Vegetation Temporal Analysis System, SATVeg, to facilitate the distinction between classes.

Keywords: Geoprocessing, Sentinel-2A MSI, Coffee, Supervised Classification, Frost.

SUMÁRIO

1. INTRODUÇÃO.....	8
2. REFERENCIAL TEÓRICO	9
2.1 O avanço da agricultura e o uso de tecnologia.....	9
2.2 Geotecnologias e sua importância para a cafeicultura	10
2.3 Classificação de imagens.....	11
2.3.1 Classificação supervisionada.....	12
2.3.1.1 Métodos de classificação supervisionada	12
2.3.2 Classificação não-supervisionada	14
3. MATERIAL E MÉTODOS	14
3.1 Área de estudo.....	14
3.2 Aquisição das imagens de satélite	15
3.3 Classificação das imagens de satélite.....	16
3.4 Pós - processamento.....	17
3.5 Avaliação estatística	18
4. RESULTADOS E DISCUSSÕES	18
5. CONCLUSÃO	24
REFERÊNCIA.....	25
ANEXO	29

1. INTRODUÇÃO

O Brasil é reconhecido mundialmente pela qualidade e pelo sabor de seus grãos de café, devido as características das altitudes dos locais de produção que trazem qualidades únicas no aroma (BARBOSA et al., 2011), isso cria uma crescente demanda pelo mercado de exportação. Segundo dados do CONSELHO DE EXPORTADORES DE CAFÉ DO BRASIL (CECAFÉ, 2022), o país é o maior exportador de café no mundo, tendo mercados como Estados Unidos, Alemanha, Itália e Bélgica como seus maiores consumidores. Em 2022, cerca de U\$9,233 bilhões foram arrecadados com a exportação do café, valor recorde até então. Mesmo sob o ciclo de bienalidade negativa, 2023 superou a produção comparada a safra anterior, com destaque aos estados do Espírito Santo, Bahia, Rondônia, Rio de Janeiro e Goiás. (CONAB, 2023). Tanto na exportação, quanto no consumo nacional, Minas Gerais é hoje um dos principais polos de café do país (CONAB, 2022). Também foi possível observar que 70,7% do volume total de café produzido foi da espécie arábica (*Coffea arábica* L.), com aproximadamente 38,9 milhões de sacas (CONAB, 2023).

O monitoramento de áreas cafeeiras é um importante recurso para os produtores, pois permite desenvolver planos de trabalho conforme a sua necessidade. Com isso, o mapeamento se torna muito relevante para o produtor, pois quando auxiliado de geotecnologias e com o trabalho de campo, é possível minimizar o tempo e o custo para um planejamento sustentável (SOUZA et al., 2009), o que acarreta em ganhos na produção final. O Sensoriamento Remoto (SR), uma importante área das geotecnologias, tem se mostrado relevante nos últimos anos, com aplicações em diversos segmentos do agronegócio. Como exemplo, é possível citar um estudo que alcançou 90% de acerto na estimativa do potencial produtivo do cafezal com 8 meses de antecedência utilizando o índice de vegetação NDVI obtido de imagens do satélite Sentinel-2 (SOARES, 2021). O SR também é capaz de dimensionar grandes perdas envolvendo catástrofes ambientais, das quais podem causar danos por diversos ciclos. Em 2021 o frio intenso provocou uma grande geada em alguns municípios produtores de café em Minas Gerais. Foi possível, através de uma análise temporal, quantificar as áreas afetadas pela geada e seu potencial dano, apresentado pelo Relatório Técnico desenvolvido pelo IF Sul de Minas Campus Muzambinho (PEREIRA et al., 2021). Tal impacto na produtividade é relatado no quarto levantamento realizado pela Conab, que em 2022, ano de alta bienalidade, apresentou

uma redução de 19,3% quando comparado ao ano de 2020, consequência direta do déficit hídrico e das geadas no ano de 2021 (CONAB, 2022).

O objetivo geral deste trabalho foi realizar um mapeamento temporal das áreas cafeeiras da região sul do estado de Minas Gerais.

Para tal, teremos os seguintes objetivos específicos:

- Avaliar as diferenças nas áreas entre os anos de 2019 e 2023;
- Executar uma classificação fazendo o uso de imagens de alta resolução espacial Sentinel-2A MSI;
- Comparar as classificações supervisionadas dos algoritmos de Máxima Verossimilhança, Mínima Distância e *Spectral Angle Mapper*;
- Avaliar o melhor métodos através dos indicadores da matriz de confusão;
- Testar a eficácia do método de pós-processamento.

2. REFERENCIAL TEÓRICO

2.1 O avanço da agricultura e o uso de tecnologia

A agricultura está diretamente ligada à sobrevivência e ao avanço das civilizações pelo mundo. MAZOYER e ROUDART (1997) relatam a domesticação do trigo desde 9500 anos a.C., época em que se fazia necessário o desenvolvimento de cultivares para a sobrevivência das comunidades. Além disso, o uso da tração animal veio como uma boa ferramenta para auxiliar pequenos agricultores que não possuíam grande mão de obra e que buscavam o aumento da produtividade, uma vez que as áreas poderiam continuar as mesmas e o ciclo entre as culturas seria melhor distribuído (EMBRAPA, 1993). Com o tempo, a produção de alimentos passou por várias mudanças e o Brasil começou a ter uma função importante, se tornando o terceiro maior exportador de produtos agrícolas e alimentos do mundo, segundo a *WORLD TRADE STATISTICAL REVIEW* (2023), ficando atrás apenas dos Estados Unidos e União Europeia. Nesse sentido, SAATH e FACHINELLO (2016) não descartam a ideia de que para o Brasil atender as demandas da população até 2024, seja necessário a expansão da produtividade e da área plantada. Pensando nisso, o conceito de Agricultura de Precisão (AP) vem ganhando forças, uma vez que empregar novas tecnologias acarreta a diminuição do uso excessivo de insumos, buscando a maximização dos lucros e, como consequência, o aumento da produtividade

(BORGES et al., 2022). FAULIN e MOLIN (2007) mostram em seus experimentos o ganho de produção em duas áreas de café arábica (*Coffea arabica* L.) utilizando Nitrogênio, Fósforo e Potássio em doses variáveis no manejo de adubação. Pesquisas nessa área se fazem necessárias e mostram a força que a AP e de ferramentas de análise espaciais auxiliam nas tomadas de decisão, ajudando no mapeamento e monitoramento de culturas (PEREIRA et al., 2017).

2.2 Geotecnologias e sua importância para a cafeicultura

O Sensoriamento Remoto surgiu como um instrumento que visa obter imagens da superfície terrestre, sem a necessidade de contato físico com os objetos, onde sensores são capazes de captar a radiação eletromagnética que é refletida desses materiais (MENDES e DE ALMEIDA, 2012). Com o avanço da tecnologia, algumas ferramentas de geoprocessamento, como é o caso do SR, tem se consolidado cada vez mais ao longo dos anos, desempenhando um papel crucial nas tomadas de decisão, mas que ainda exige uma mão de obra especializada (BERNARD et al., 2014). Entender e aplicar essas técnicas auxiliam os produtores a prever as suas safras, pois o mercado também sofre a influência das especulações. RIBEIRO et. al (2006) observaram que a variabilidade do preço do café arábica está relacionada aos estoques e às exportações e, desse modo, prever safras ou possíveis danos por catástrofes ambientais acaba se tornando uma ferramenta muito útil. SOARES (2020) mostrou que é possível estimar o potencial produtivo do cafezal com até 8 meses de antecedência, usando o NDVI (Índice de Vegetação por Diferença Normalizada) como base, relacionando a produtividade alcançada nos anos de estudo. Outras pesquisas (RAFAELLI, 2004; PETSCH e BUENO, 2013) mostram como o NDVI também apresenta boa correspondência com fatores climáticos adversos, em específico a geada, acarretando em danos as estruturas internas da vegetação e, conseqüentemente, a queda da produção. Esse impacto na produtividade pode ser observado no quarto levantamento realizado pela CONAB, que em 2022, ano de alta bienalidade, apresentou uma redução de 19,3% quando comparado ao ano de 2020, conseqüência direta do déficit hídrico e das geadas no ano de 2021.

O café é uma das culturas de maior importância para o Brasil, pois, além de produtor, é um grande consumidor da bebida. De acordo com dados da ABIC (Associação Brasileira da Indústria de Café, 2022), o consumo dessa bebida no país, em 2022, atingiu 21,3 milhões de sacas, representando 41,8% da mesma. Atualmente, somos o maior

produtor mundial da *commodity*, segundo dados da *International Coffee Organization* (ICO, 2022). Tendo em vista a importância da indústria do café para o PIB brasileiro, nosso país se mostra bastante vulnerável a eventos climáticos extremos. Alguns eventos de grandes magnitudes já foram documentados no estado do Paraná em 1975, onde a chamada “Geada negra” acabou com toda a produção no ano seguinte. A geada em 2021 foi um grande problema para a produção no estado de Minas Gerais, segundo um relatório técnico apresentado pelo Instituto Federal Sul de Minas de Muzambinho (PEREIRA et al., 2021). Esse relatório mostra que, de toda a área de estudo de 823.235 ha, aproximadamente 126.366 ha, correspondendo a cerca de 15,35%, foram atingidas pela geada, ocorrida no dia 20/07/2021. CUNHA (2021) também relata danos pela geada no município de Patrocínio e quantifica os danos causados, assim como sua severidade. De acordo com ALVES et al. (2021), a geada tem como consequência a perda do suco celular, provocando assim os sintomas visíveis, como desidratação, queima dos tecidos e morte, tanto da planta quanto de suas partes reprodutivas. Os danos podem ser divididos em três origens:

- Quando os líquidos intracelulares congelam, se expandem e com o aumento da pressão osmótica, rompem as células, levando à sua morte;
- Os ponteiros dos cristais de gelo perfuram as células e as organelas responsáveis pelo metabolismo vegetal, como por exemplo, a produção de energia nas mitocôndrias e a produção de clorofila pelos cloroplastos, ocasionando a morte da célula vegetal;
- A água extracelular congela alterando o potencial hídrico e assim, atrai a água de dentro da célula, cansando uma desidratação até a sua morte.

Assim, percebe-se a grande importância de se ter o máximo controle sobre a produção, área plantada e posição geográfica das plantações de café, buscando auxiliar ainda mais nas tomadas de decisão, evitando possíveis perdas.

2.3 Classificação de imagens

A classificação de imagens de satélite vem ganhando força com o passar do tempo, uma vez que os sensores com melhores tecnologias e os novos estudos indicam a importância dessa ferramenta. O Sensoriamento Remoto (SR) e Sistemas de Informação Geográficas (SIG) são tecnologias desenvolvidas que conseguem auxiliar nas

classificações utilizando lavouras de café. Segundo MOREIRA et al. (2010), o uso de geotecnologias para o mapeamento de lavouras de café mostrou-se relevante.

A classificação pode ser dividida em supervisionada e não supervisionada. Existe uma grande variedade de métodos que podem ser associados a um conjunto de treinamentos e que, por meio de cálculos, geram mapas temáticos e uma imagem classificada (CRÓSTA, 1992).

2.3.1 Classificação supervisionada

A classificação supervisionada é a mais utilizada para fazer análises quantitativas com o uso de SR. Ela é baseada na utilização de algoritmos específicos, a fim de comparar amostras coletadas com uma classificação mais ampla. Amostras de treinamento são coletadas buscando sempre abranger toda a cobertura da imagem para que não maximize o erro ao final. De acordo com RICHARDS (1993), uma boa classificação pode ser desenvolvida com 5 passos, sendo elas:

- Escolha dos conjuntos de classe da cobertura e ocupação do solo presentes na imagem. Alguns exemplos são a vegetação arbórea, cidades, solo exposto, rios, entre outros;
- Coletar amostras de treinamento para que o algoritmo tenha os *inputs* necessários para a comparação, a depender de qual algoritmo será utilizado;
- Utilizar os dados de treinamento para ajustar os parâmetros do algoritmo que será usado. Esses parâmetros poderão ser propriedades do modelo com fatores de probabilidade ou equações, como a Máxima verossimilhança, Mínima distância ou *Spectral Angle Mapper*;
- Utilizar o classificador para rotular ou classificar a imagem, comparando pixel a pixel com as classes já definidas. Para tal, é necessário conhecer ao menos 1% dos pixels que serão classificados para que o algoritmo processe a classificação dos demais;
- Serão produzidos os mapas temáticos com as devidas classes, que podem ser validadas com base nas acurácias de classificação.

2.3.1.1 Métodos de classificação supervisionada

Máxima verossimilhança (MaxVer): É um dos métodos mais utilizados quando se trata da classificação de imagens coletadas por sensores remotos, por utilizar parâmetros estatísticos comumente aceitos e apresenta melhores resultados quando comparado aos outros métodos. O algoritmo de máxima verossimilhança vem para solucionar problemas comuns, ao classificar valores de pixels que não foram treinados, e atribui um valor máximo para tal. CRÓSTA (1992) cita que é necessário um número elevado de pixels no treinamento, pois assim assegura que a área esteja bem amostrada, capturando variações de valores covariantes. MARINHO et al. (2017) desenvolveu uma metodologia em que foi verificada a mudança temporal do uso e ocupação do solo, nos anos de 2007 a 2017 e obteve resultados excelentes. O mapeamento de culturas de café utilizando técnicas de SR e métodos de classificação passaram a ser uma boa ferramenta no planejamento, atingindo um efeito bastante positivo quando utilizadas para mapear cafés em produção e cafés em formação. (DO PRADO et al., 2015). CAMPANHA et al. (2018), também utilizou os métodos de MaxVer para o mapeamento de lavouras de café.

Mínima distância (MD): O método da mínima distância visa solucionar os valores de pixels que não foram treinados, podendo ser uma questão de proximidade ou de similaridade. É um método que se baseia em cálculos estatísticos, onde, segundo CRÓSTA (1992), é a média estatística para cada uma das classes em cada banda espectral, ou seja, atribuir cada pixel a uma classe cuja média é mais próxima a ele. RICHARDS (1993) relatam o método da mínima distância como um método que pode auxiliar quando o número de amostras de treinamento é limitado, sem a necessidade de se usar informações covariantes, mas que dependa apenas da média mínima das classes. DA ROSA (2015) também cita o método como satisfatório quando classificado com sensores de alta resolução espacial. MÜLLER (1997), através do seu estudo, pode concluir que o método de mínima distância tinha uma boa classificação quando feito de forma aleatória e também de forma controlada.

Spectral Angle mapper (SAM): O algoritmo SAM também é comumente utilizado em sensoriamento remoto. Funciona atribuindo pixels a diferentes classes com base nas semelhanças entre espectros observados e de referência. Esse algoritmo se baseia na medição da similaridade espectral entre dois espectros. Essa similaridade é obtida considerando cada espectro como um vetor no espaço q-dimensional, onde q é o número de bandas da imagem e se calcula o ângulo entre eles (RASHMI et al, 2014).

CARVALHO JUNIOR e MENESES (2000) citam que a grande limitação do algoritmo é avaliar apenas os ângulos avaliados, ignorando a relação entre eles, o que acaba impossibilitando de distinguir correlações positivas (diretamente proporcional) e negativas (inversamente proporcional).

2.3.2 Classificação não-supervisionada

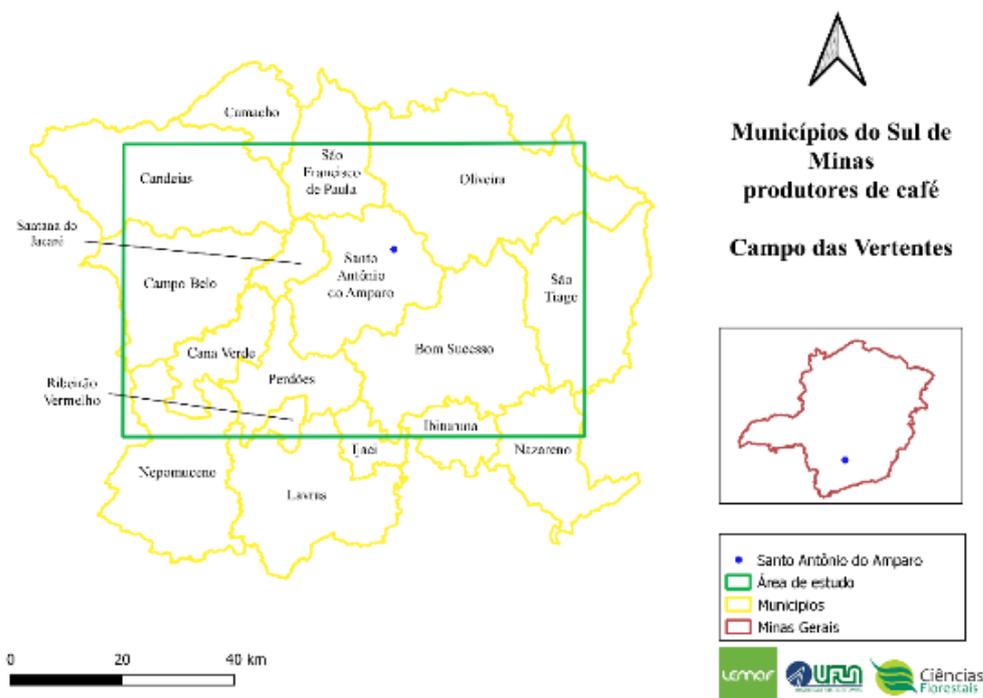
A classificação não supervisionada se baseia na capacidade do computador, através do software utilizado, de identificar as classes em um conjunto de dados de forma autônoma. Envolve a análise dos atributos de todos os pixels de uma imagem, e não apenas dos pixels das áreas de treinamento. O primeiro passo é realizar um processo de agrupamento, utilizando técnicas estatísticas para identificar os dados no espaço de atributos. Em seguida, é preciso decidir quais grupos devem ser considerados separados. Uma abordagem comum é aceitar apenas os picos que ultrapassam um determinado limite, levando em conta a altura dos picos em relação às depressões adjacentes e aceitando apenas aqueles acima de um limite específico. Esse método permite a identificação de padrões e estruturas nos dados de forma não supervisionada, sem a necessidade de informações prévias sobre as categorias das imagens (CRÓSTA, 1992).

3. MATERIAL E MÉTODOS

3.1 Área de estudo

O estudo foi realizado na região do Sul de Minas Gerais, em municípios pertencentes a mesorregião do Campo das Vertentes, importante região na produção de café do estado (Figura 1). A região de estudo possui área de 437.192 hectares, com uma janela de 82,6 km por 53 km. O clima é classificado como Cwa, subtropical úmido, com verões quentes e úmidos e invernos frios e secos, segundo a classificação de Köppen, com temperatura média anual de 19,3°C. Para a realização deste trabalho, contamos com alguns arquivos vetoriais que foram obtidos no site do INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE, 2023).

Figura 1 - Mapa de localização dos municípios do Sul de Minas Gerais, com alguns pertencentes a mesorregião do Campo das Vertentes.



Fonte: do autor (2024).

3.2 Aquisição das imagens de satélite

O processamento dos dados foi realizado pelo programa computacional quantum GIS (Qgis), versão 3.22.5 Białowieża, especificamente para classificação das imagens utilizamos o *Semi-Automatic Classification Plugin* (SCP) versão 7.10.11. O SCP é uma ferramenta de código aberto que foi desenvolvida por Luca Congedo. Essa ferramenta nos permite elaborar uma classificação supervisionada, pré-processamentos e pós processamentos dos dados, coletando amostras de acurácia para o cálculo da matriz de confusão e das medidas de acurácia: acurácia global, acurácia do produtor e acurácia do usuário.

As imagens selecionadas foram as do satélite Sentinel-2A MSI, com resolução espacial de 10 metros, extraídas da plataforma EOS Data Analytics (2023). Para minimizar o efeito de borda, utilizamos uma área em que fosse possível o processamento dos dados sem a interferência da mesma. As bandas espectrais utilizadas foram as do

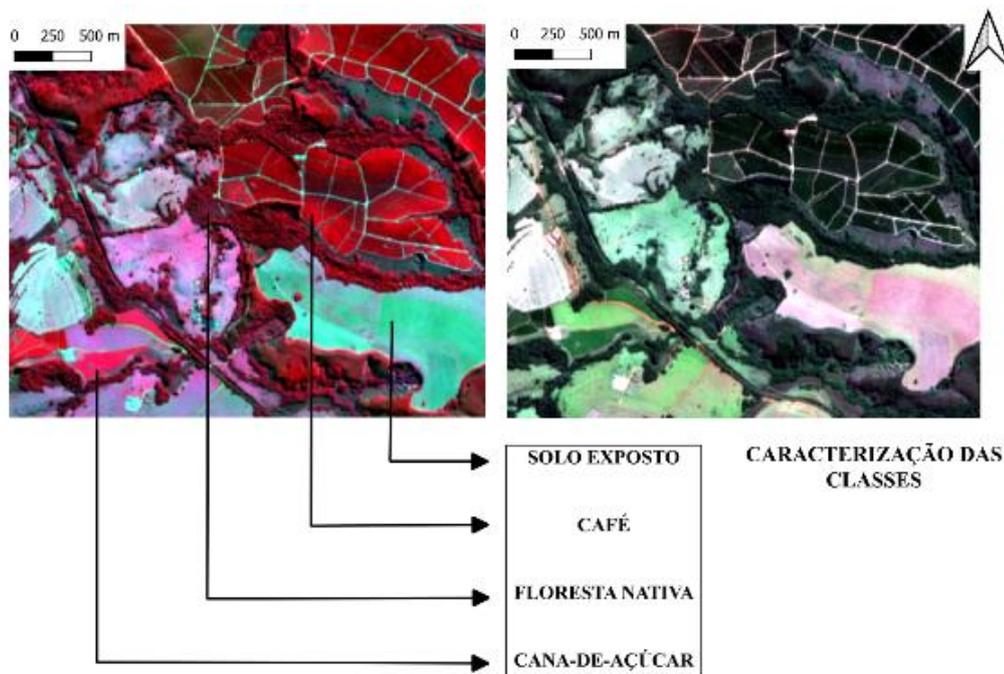
Vermelho (4), Verde (3), Azul (2) e Infravermelho próximo (8). As melhores imagens encontradas foram as do mês de Junho, sendo 26/06/2019 e 10/06/2023, pois segundo MOREIRA et al. (2003), a melhor época de aquisição das imagens para o mapeamento do café é entre Junho e Setembro, pois a incidência de nuvens é menor. Foi utilizado também para validação nas demais áreas, o banco de dados da EMBRAPA, o SATVeg – Sistema de Análise Temporal da Vegetação (<https://www.satveg.cnptia.embrapa.br>). Esta ferramenta é capaz de gerar imagens NDVI (Índice de Vegetação por Diferença Normalizada) numa série temporal, que auxiliaram nas coletas das amostras. O SATVeg é um sistema baseado na web para rápido acesso e visualização de séries temporais de índices de vegetação na América do Sul. Esse sistema utiliza imagens do sensor MODIS do satélite TERRA e ÁGUA, com 250 metros de resolução espacial e resolução temporal de 16 dias (ESQUERDO et al., 2020).

3.3 Classificação das imagens de satélite

A classificação no SCP foi realizada na forma supervisionada, onde é necessário o fornecimento de amostras de treinamento que recebem o nome de *Region of Interest* (ROI). Essa amostra é reconhecida através de um polígono e armazenada. Para este estudo, as classes coletadas foram: 1- Café (em formação e em produção), 2- Florestas (nativas e plantadas), 3- Outros usos (solo exposto, afloramentos rochosos, rodovias, corpos hídricos e cidades) e 4- Uso agropecuário (pastos e culturas de cana-de-açúcar). Podemos ver exemplos dessas culturas na Figura 2. A estratégia para a coleta das amostras de treinamento foi aleatória. Como norma, foi utilizado o mesmo conjunto de treinamento nos diferentes algoritmos de classificação, a fim de garantir uma amostragem sem nenhuma variação. Após serem coletados, os pixels são avaliados individualmente, de acordo com suas características espectrais. Utilizamos três possibilidades de classificação supervisionada, a de Máxima Verossimilhança (MaxVer), Mínima Distância (MD) e a *Spectral Angle Mapper* (SAM). Todas as imagens passaram pelas 3 três classificações, a fim de que fosse selecionada a que apresentasse os melhores resultados.

Para o cálculo da acurácia, foi criado um GRID amostral, com espaçamento de 0,5ha de distância entre os dados coletados de forma sistemática, para uma melhor amostragem da área, sendo coletados 190 pontos em ambos os anos de classificação.

Figura 2: Exemplos das amostras de treinamento em falsa cor e em cor verdadeira na imagem Sentinel 2.



Fonte: do autor (2024).

3.4 Pós - processamento

Para melhorar a acurácia dos processamentos, utilizamos um filtro majoritário em todas as classificações. É muito comum em mapeamentos de grandes áreas, uma ligeira confusão entre as classes, o que chamamos de efeito “sal e pimenta”, que normalmente acontece quando classes distintas apresentam valores semelhantes na coleta das amostras. Uma das soluções mais eficazes para limpeza da classificação produzida foi a aplicação do filtro *majority filter*, uma ferramenta do próprio Qgis com o pacote SAGA. Essa técnica tem como objetivo melhorar os valores de acurácia e o visual do mapa, auxiliando na remoção de possíveis erros de classificação isolados. O filtro foi testado com valor de 4 pixels para ser comparada com a classificação Sem Filtro (SF). PEREIRA e GUIMARÃES (2019) citam que a utilização do filtro majoritário foi utilizada para uma melhor qualidade visual sem perda de acurácia no mapa final. BARBOSA (2022) também utiliza o filtro para minimizar os efeitos “sal e pimenta” da classificação.

3.5 Avaliação estatística

A avaliação da acurácia foi realizada no próprio SCP, abrangendo a acurácia global, acurácia do usuário, a acurácia do produtor e o índice Kappa. As amostras foram calculadas de acordo com uma matriz de confusão baseada na área da amostra, sendo que cada amostra representava um fragmento da área estimada para cada classe (OLOFSSON et al., 2014). Optou-se pelo uso do índice Kappa para a avaliação geral da classificação e para uma análise mais rigorosa, foi utilizado os valores de células marginais, que incluem os erros de omissão (quando o algoritmo falha em classificar um produto que deveria pertencer a uma classe e os erros de comissão, quando o mesmo classifica erroneamente um produto em uma classe à qual não pertence (FERREIRA et al., 2007).

Tabela 1 – Valores de Kappa e sua respectiva concordância.

Valor de Kappa		Concordância	
<	-	0,2	Pobre
0,21	-	0,4	Fraca
0,41	-	0,6	Moderada
0,61	-	0,8	Boa
0,81	-	1	Muito boa

Fonte: GALPARSORO e FERNÁNDEZ adaptado (2001).

4. RESULTADOS E DISCUSSÕES

Por meio de comparação visual, todos os algoritmos apresentaram uma boa classificação. No entanto, ao serem comparadas pela matriz de confusão, para os dois anos de estudo (Tabela 2), percebe-se uma acurácia mais assertiva com o algoritmo Maxver, Com e Sem filtro, seguidos do MD e SAM, respectivamente. Como resultado, é possível observar os mapas de uso e ocupação do solo presente na área de estudo, nos períodos de 2019 e 2023. (Figura 3 e 4). Esse resultado era esperado, conforme relatado por outros autores que destacaram a eficácia dos resultados pelo algoritmo de Máxima Verossimilhança (MÜLLER, 1997; CRÓSTA, 1992), pois quando comparamos o valor da acurácia global, MaxVer obteve os melhores resultados, e quando comparados as acurácias do produtos e do usuário, também foram observados melhores resultados.

Também é possível notar um baixo erro de comissão nas classes “Café” E “Florestas” com esse algoritmo. A classe “Café” obteve valores antes da filtragem em 2019 de 19,5%, e após o filtro, esse valor reduziu para 1,64%. Esse padrão também ocorreu em 2023, quando os valores passaram de 1,09% para 0,32%, respectivamente sem e com filtro.

Na Tabela 3, fica evidenciada melhorias notáveis nos índices de acurácia em comparação com períodos anteriores. Observa-se que, após a aplicação da filtragem em 2019, a classe "Café" teve um aumento de 8,03% na acurácia do usuário e de 17,86% na acurácia do produtor para o algoritmo de MaxVer, resultando em uma redução significativa nos erros de comissão e omissão. Em 2023, os erros de omissão e comissão foram minimizados, alcançando os menores valores em comparação com 2019. Em ambos os anos de processamento, a classe "Florestas" demonstrou resultados satisfatórios, apresentando os menores erros de omissão em relação a todas as classes. Por outro lado, a classe "Usos agropecuários" em 2023 exibiu o pior desempenho, com uma taxa de erros de comissão de 50,0109% antes da filtragem, e mesmo após a aplicação do filtro, não houve uma melhoria significativa.

Tabela 2 - Comparativo entre os classificadores de imagens de 2019 e 2023 Com e Sem filtro.

Qualidade	2019		2023	
	Sem filtro	Com filtro	Sem filtro	Com filtro
Maxver	Boa	Muito boa	Boa	Muito boa
MD	Moderada	Boa	Moderado	Boa
SAM	Fraca	Moderada	Moderado	Boa
Acurácia (%)				
Maxver	78,57%	90,22%	81,91%	91,54%
MD	70,20%	72,63%	67,48%	73,66%
SAM	53,02%	58,86%	65,67%	73,80%
Coef. Kappa				
Maxver	0,70	0,86	0,75	0,88
MD	0,59	0,62	0,57	0,65
SAM	0,36	0,42	0,53	0,63

Fonte: do autor (2024).

É possível notar uma grande diferença entre as classes “Outros usos” e “Usos agropecuários”, tendo em vista que as áreas podem ser facilmente confundidas pela época mais seca do ano, em que as pastagens sofrem mais pela falta de precipitação. RINALDI

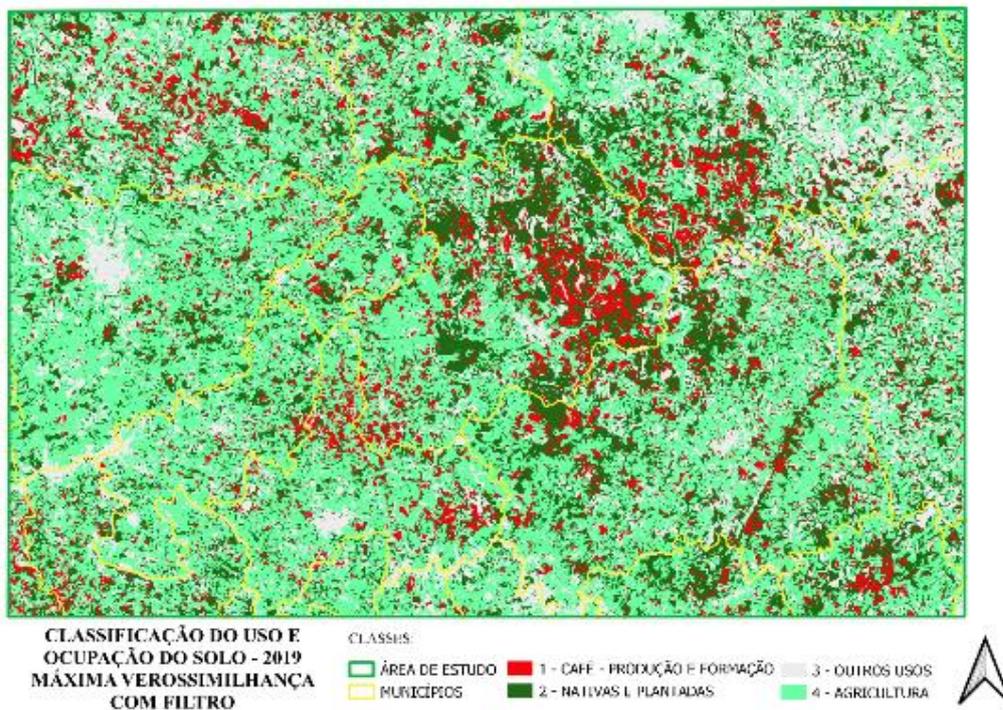
e ROSA (2022) realizaram um estudo na cidade de Campina da Lagoa – PR, onde concluíram que a vegetação se comportou de acordo com a precipitação, apresentando valores altos de NDVI em períodos chuvosos e, para meses secos, houve degradação na pastagem, mostrando assim o papel fundamental da disponibilidade hídrica para a qualidade ambiental da área. Também é possível ver um aumento na classe “Café” nos municípios de Santo Antônio do Amparo, Candeias e Oliveira.

Tabela 3 - Comparativo entre a acurácia do usuário, acurácia do produtor, erros de omissão e erros de comissão nos anos de 2019 e 2023 Com e Sem filtro do algoritmo de Máxima Verossimilhança.

	2019		2023	
	Sem filtro	Com filtro	Sem filtro	Com filtro
Classes	Acurácia do usuário (%)			
Café	74,2194	82,2469	83,9209	93,2855
Florestas	95,2182	99,3714	94,3180	96,7443
Outros usos	88,6715	93,4885	69,6580	83,4222
Usos agrop.	66,8855	85,9082	84,4208	97,6549
Classes	Erro de comissão (%)			
Café	25,7806	17,7531	16,0791	6,7145
Florestas	4,7818	0,6286	5,6820	3,2557
Outros usos	11,3285	6,5115	30,3420	16,5778
Usos agrop.	33,1145	14,0918	15,5792	2,3451
Classes	Acurácia do produtor (%)			
Café	80,4915	98,3506	98,9007	99,6714
Florestas	86,6966	90,9908	82,7470	93,4009
Outros usos	67,6887	85,4717	90,3183	97,9077
Usos agrop.	94,4972	95,3916	49,9891	68,2819
Classes	Erro de omissão (%)			
Café	19,5085	1,6494	1,0993	0,3286
Florestas	13,3034	9,0092	17,2530	6,5991
Outros usos	32,3113	14,5283	9,6817	2,0923
Usos agrop.	5,5028	4,6084	50,0109	31,7181

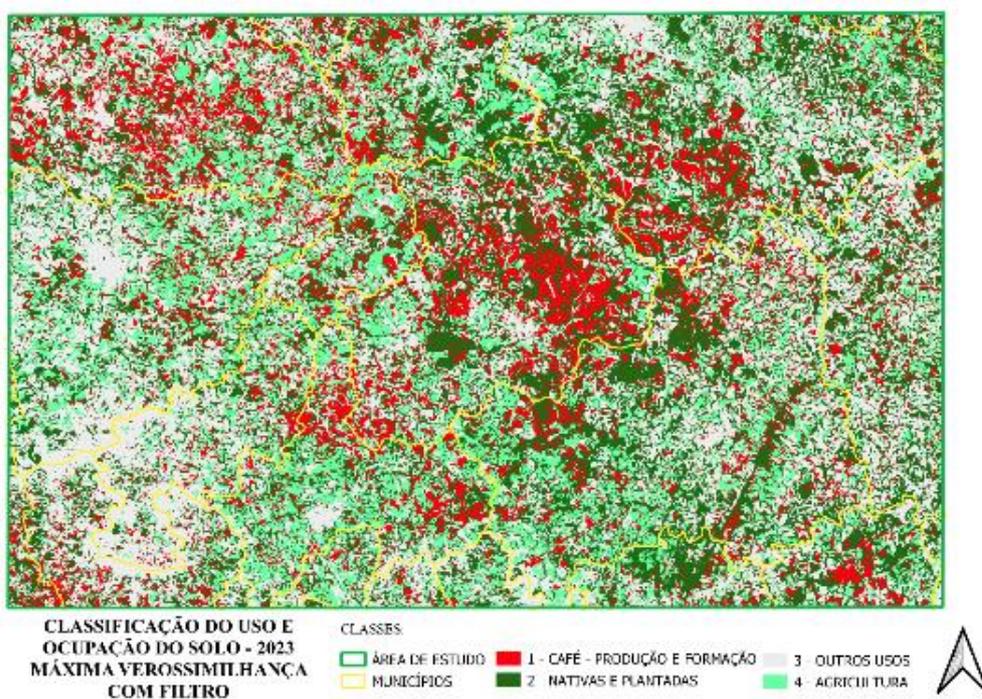
Fonte: do autor (2024).

Figura 3 – Mapa de uso e ocupação do solo do ano de 2019 obtido pelo método de Máxima Verossimilhança.



Fonte: do autor (2024).

Figura 4 – Mapa de uso e ocupação do solo do ano de 2023 obtido pelo método de Máxima Verossimilhança.

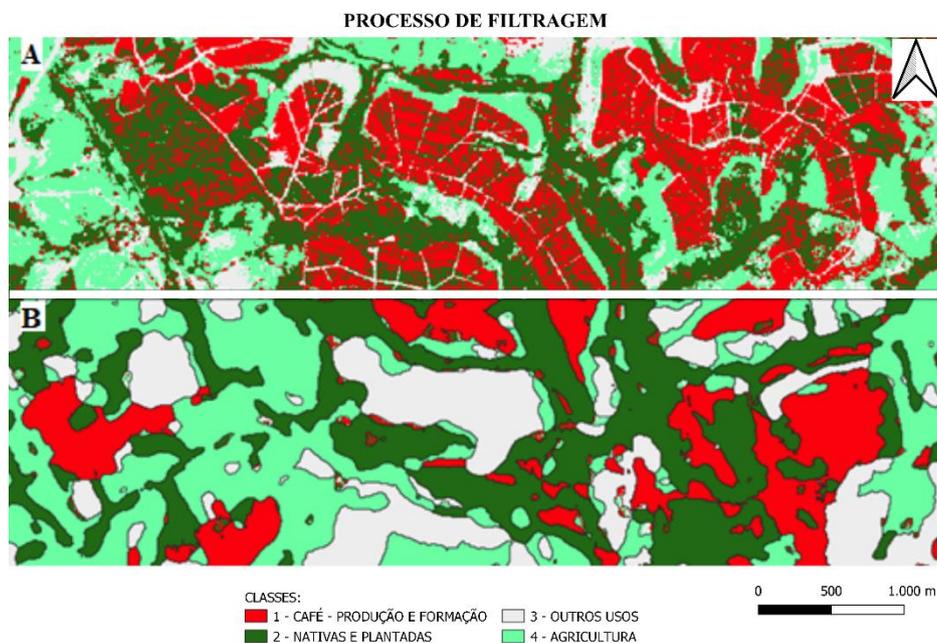


Fonte: do autor (2024).

A filtragem de 4 pixels na classificação apresentou uma melhora significativa em todos os processamentos, resultando assim num aumento nos índices de qualidade. Destaca-se que a classificação de Máxima Verossimilhança apresentou a melhor acurácia global e índice kappa nos dois anos, com valores de, respectivamente, 78,5664% e 0,6981 em 2019 e 81,9096% e 0,7537 em 2023. Após filtragem, em 2019, os valores subiram para 90,2225% e 0,8574, enquanto que em 2023, os valores passaram para 91,5425% e 0,8842. A qualidade de ambos os processamentos alterou de “Boa” para “Muito boa” segundo o índice Kappa. Na Figura 5 é possível visualizar o antes (A) e depois (B) da filtragem e como ela minimiza os problemas apresentados de “sal e pimenta”. Mesmo com um número maior de amostras no ano de 2023 na classe “Café”, o problema não foi totalmente resolvido.

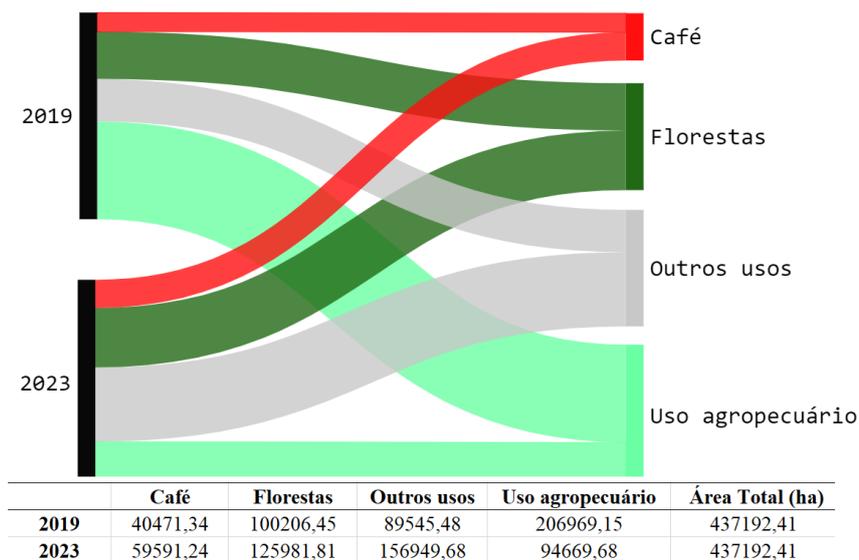
Através do quadro de áreas (Figura 6), percebe-se um aumento de 46,10%, equivalente a 19119,91 hectares de café em toda a extensão estudada, característica importante pois evidencia que a região, como grande polo na produção de café, permanece em ascensão, mesmo com grandes problemas climáticos que atingem o estado. Um estudo conduzido por ALVES et al. (2019) caracterizou o Campo das Vertentes em relação à extensão das plantações de café, destacando Santo Antônio do Amparo, Candeias e Oliveira como os principais municípios com grandes áreas cultivadas.

Figura 5 – Antes e depois da filtragem pelo Majority filter com 4 pixels.



Fonte: do autor (2024).

Figura 6 – Representação gráfica e quadro de áreas classificadas nos anos de 2019 e 2023.



Fonte: do autor (2024).

Observa-se que nas classificações de todos os algoritmos, em ambos os anos, ocorreu muita confusão no processamento com as classes “Café” e “Florestas”, com grande similaridade de valores. De acordo com estudos realizados por MARTÍNEZ-VERDUZCO, GALEANA-PIZAÑA e CRUZ-BELLO (2012), citados por ABRANTES e PITHAN (2018), esses resultados indicam que a resposta espectral do cafeeiro e da vegetação natural são muito semelhantes.

O SATVeg desempenhou um papel importante pois fomos capazes de sanar possíveis dúvidas nas classificações e entender melhor o comportamento temporal da vegetação estudada. Como citado anteriormente, é possível notar essa grande similaridade espectral apresentada pelas classes “Café” e “Florestas” e como isso também foi evidenciado na classificação final, com uma maior ocorrência de erros.

Figura 7 – Diferença espectral entre as classes Café e Floresta Nativa pelo SATVeg.



Fonte: do autor (2024).

Podemos observar no Anexo 1, a tabela com a matriz de confusão sobre todas as classificações, Com e Sem Filtro para ambos os anos. O algoritmo Maxver, o melhor entre as três opções, teve poucos problemas com as classes, obtendo os melhores índices Kappa. Notou-se que este algoritmo teve uma boa resposta para classificar a classe café, quando comparado aos outros, mas que ainda apresentou erros que só puderam ser melhorados com a filtragem. Para a classe de “Usos agropecuários”, este algoritmo teve grandes confusões quando comparados com “outros usos” e “Florestas”.

Na classificação da Mínima Distância, a matriz revelou um padrão de similaridade entre todas as classificações, com uma pequena melhora após a aplicação do filtro no índice global. Para a classe “Usos agropecuários”, observou-se uma melhoria com o uso do filtro, mas que piorou em relação à classe “Florestas” quando comparada a “Café”. Uma possível causa para essa melhora seria que, assim como o exemplo do MaxVer, o filtro ajudou a retirar pixels isolados e agrupar um número maior de valores próximos, fazendo com que a qualidade da classificação fosse elevada de “Moderada” para “Boa”. Houve uma boa resposta quando comparamos com “Florestas” e “agricultura”, mas, “café” e “Outros usos” não obteve nenhuma confusão, muito pela diferença espectral entre as classes.

Quanto à classificação de SAM, observamos uma piora sutil nas classificações do ano de 2019, com “Café” e “Florestas” e uma enorme confusão entre “Usos agropecuários” e “Café”, “Florestas” e “Outros usos”. Foi a pior classificação entre todas e que, mesmo com o filtro, apresentou valores altos de confusão.

5. CONCLUSÃO

Conclui-se que houve um aumento da área cafeeira na região de estudos, deixando evidente o grande impacto da região do Sul de Minas como uma grande produtora de café e que permanece em crescimento.

O melhor algoritmo de classificação foi o de Máxima Verossimilhança, apresentando os melhores valores para a classificação. O aplicativo Semi-automatic Classification se mostrou muito bom para realizar classificações em grandes áreas, com a vantagem de ser totalmente *open source*, trazendo assim uma ótima opção para pequenos produtores que não precisam investir em licenças de aplicativos pagos.

Os algoritmos testados nesse trabalho apresentaram grandes dificuldades na discriminação entre as classes de Café e Florestas, problema que se deve a grande semelhança entre os espectros de refletância do verde. Isso também deixa evidente a importância da verdade de campo para classificações em grandes áreas. A utilização do SATVeg demonstrou ser uma ferramenta eficaz na comparação dos índices de NDVI, facilitando a distinção entre diversas classes e ajudando a esclarecer dúvidas.

O uso do majority filter com 4 pixels também foi muito eficiente na pós-classificação, melhorando todos os resultados finais.

REFERÊNCIA

ABIC. ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE CAFÉ. **Estatísticas – indicadores da indústria de café no Brasil**. 2022. Disponível em: <<https://estatisticas.abic.com.br/estatisticas/indicadores-da-industria/indicadores-da-industria-de-cafe-2022/>>, Acesso: 27/10/2023.

ABRANTES, Tales; PITHAN, Pâmela Aude. Discriminação da cobertura vegetal utilizando índices derivados do sentinel 2A - MSI. **VII Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação**, p. 1-8, 14 nov. 2018.

ALVES, Helena Maria Ramos *et al.* Caracterização das áreas cafeeiras da região do campo das vertentes. **X Simpósio de Pesquisa dos Cafés do Brasil**, p. 1-7, 11 out. 2019.

ALVES, José Donizeti *et al.* Danos fisiológicos da geada sobre o cafeeiro nas regiões Sul e Cerrado de Minas Gerais. **EPAMIG**, Belo Horizonte, n. 360, p. 1-4, dez. 2021.

BARBOSA, Giovane Gussoni. **Mapeamento de lavouras de café e de áreas propícias a expansão de lavouras cafeeiras no município de Monte Carmelo - MG**. 2022.

BARBOSA, Juliana Neves *et al.* A expressão da qualidade do café natural produzido em diferentes ambientes da microrregião da Serra da Mantiqueira. **VII Simpósio de Pesquisa dos Cafés do Brasil**, Araxá, MG, p. 1-6, 22 ago. 2011.

BERNARDI, Alberto Carlos de Campos *et al.* **Agricultura de precisão: Resultados de um novo olhar**. Embrapa, Brasília, DF, v. 1, p. 1-600, 2014.

BORGES, Lino Carlos *et al.* Agricultura de precisão: ferramenta de gestão na rentabilidade e produtividade de grãos. **Scientific Electronic Archives**, v. 15, n. 3, Disponível em: <<https://doi.org/10.36560/15320221520>>, p. 1-6, 28 fev. 2022.

CAMPANHA, Guilherme Fernandes *et al.* Uso de imagens Landsat-8 no mapeamento das lavouras cafeeiras nos municípios do entorno do Parque Nacional do Caparaó. **Essentia**, v. 20, n. 1, p. 6-17, 9 dez. 2018.

CARVALHO JÚNIOR, Osmar Abílio de; MENESES, Paulo Roberto. Spectral Correlation Mapper (SCM): An Improvement on the Spectral Angle Mapper (SAM). **Semantic scholar**, p. 1-9, 2000.

CECAFÉ, **Conselho de Exportadores de Café do Brasil**, Disponível em: <<https://www.cecafe.com.br/publicacoes/noticias/exportacao-dos-cafes-do-brasil-tem-receita-recorde-de-us-92-bilhoes-em-2022-20230116/>>, 27 out. 2023.

CONAB, Companhia Nacional de Abastecimento, **Acompanhamento safra brasileira de café**, Acomp. safra brasileira de café, v. 9 – Safra 2022, n.4 - Quarto levantamento, Brasília, p. 15-17, dezembro 2022.

CONAB, Companhia Nacional de Abastecimento, **Acompanhamento safra brasileira de café**, Acomp. safra brasileira de café, v. 10 – Safra 2023, n.4- Quarto levantamento, Brasília, p. 8-12, dezembro 2023.

CRÓSTA, Alvaro Penteado. Processamento digital de imagens de sensoriamento remoto. **Instituto de Geociências Departamento de Metalogênese e Geoquímica**, p. 1-139, 1992.

CUNHA, J. E. F., Dano por geada e sua relação com formatos de vertentes em Patrocínio - Minas Gerais, **Revista Educação Saúde & Meio Ambiente**, Patrocínio, v. 1, n. 9, p. 236 – 249, out., 2021.

DA ROSA, Elaine Nisa. **Classificação por mínima distância euclidiana de séries temporais ndvi – modis para reconhecimento de padrões vegetacionais e de uso na mesorregião sul maranhense**. 2015.

DO PRADO, Daniel Fernando Costa *et al.* Mapeamento do cultivo de café no sul de Minas Gerais utilizando imagens Landsat-5 TM e variáveis topográficas. **Revista do Departamento de Geografia**, p. 1-15, Disponível em: <<http://dx.doi.org/10.11606/rdg.v31i0.103040>>, 12 dez. 2015.

EMBRAPA, **Tração animal – Vantagens do uso na pequena propriedade**. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/55553/1/FD-0800001.pdf>>, Rondônia, 1993.

ESQUERDO, Júlio César Dalla Mora *et al.* SATVeg: A web-based tool for visualization of MODIS vegetation indices in South America. **ELSEVIER**, p. 1-9, 2020.

FAULIN, Gustavo D. C.; MOLIN, José P. Utilização dos conceitos da agricultura de precisão na cultura do café (*coffea arabica* L.). **Simpósio de Pesquisa dos Cafés do Brasil**, Disponível em: <<http://www.sbicafe.ufv.br/handle/123456789/2221>>, v. 5, p. 1-5, 2007.

FERREIRA, Elizabeth *et al.* Exatidão na classificação de fragmentos de matas em imagem do satélite Cbers-CCD, no município de Lavras, MG. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, p. 1-8, 26 abr. 2007.

GALPARSORO, L.U.; FERNÁNDEZ, S.P. Medidas de concordância: El índice Kappa. **CAD Aten Primaria**, p. 169- 171,. Disponível em: <https://www.mvclinic.es/wp-content/uploads/L%C3%B3pez-de-Ullibarri-Medidas-de-concordancia_el-%C3%ADndice-Kappa.pdf>. 2001.

IBGE, **INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA**, Disponível em: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html>>, Acesso: 28 out. 2023.

ICO, *International Coffee Organization*, **Trade Statistics Tables**, 2022. Disponível em: <https://www.ico.org/trade_statistics.asp>, tabela 1 e 4, Acesso: 29/10/2023.

MARINHO, Paulo Henrique Aquino *et al.* Classificação de imagem orbital pelo método máxima Verossimilhança em Sucupira - TO. **Agrarian Academy**, v. 4, n. 7, p. 1-10, Disponível em: <<https://conhecer.org.br/ojs/index.php/agrarian/article/view/5114>>, 31 jul. 2017.

MAZOYER, Marcel. ROUDART, Laurence. **História das agriculturas no mundo: Do neolítico à crise contemporânea**. UNESP, p. 101 – 105, v. 1, 1997.

MENDES, Paulo Roberto; DE ALMEIDA, Tati. **Introdução ao processamento de imagens de sensoriamento Remoto**. Brasília, DF, 277 p. 2012.

MOREIRA, Mauricio A. Geotecnologias para mapear lavouras de café nos estados de Minas Gerais e São Paulo. **SciELO**, p. 1-13. Disponível em: <<https://doi.org/10.1590/S0100-69162010000600013>>, dez. 2010.

MOREIRA, Maurício Alves *et al.* Tecnologia de informação: imagens de satélite para o mapeamento de áreas de café de Minas Gerais. **Embrapa Café**, p. 1-11, 2003.

MÜLLER, Sonia Isoldi Marty Gama. **Comparação entre os métodos de máxima verossimilhança, distância mínima e o método de Fisher para reconhecimento de padrões em imagens coloridas**. Disponível em: <<https://hdl.handle.net/1884/44185>>, 1997.

OLOFSSON, Pontus *et al.* Good practices for estimating area and assessing accuracy of land change. **ELSEVIER**, p. 1-16, 6 mar. 2024.

PEREIRA, Allan Arantes *et al.* **Ocorrências de geadas em áreas de cafezais de Minas Gerais em 2021 – resultados**. IF Campus Muzambinho, Disponível em: <https://www.muz.ifsuldeminas.edu.br/images/2021/09/PDF/Relatorio_Geada-Final_enviado.pdf>, p. 1-16, 2021.

PEREIRA, Ludmily da Silva *et al.* Sensoriamento remoto aplicado à agricultura de precisão no cultivo de bambu. **Revista Mackenzie De Engenharia E Computação**, v. 16, n. 1, Disponível em: <

<https://editorarevistas.mackenzie.br/index.php/rmec/article/view/9972> >, p. 1-26, 10 out. 2017.

PEREIRA, Luís Flávio; GUIMARÃES, Ricardo Morato Fiúza. Mapeando usos/coberturas da terra com Semi-automatic Classification Plugin: quais dados, classificador e estratégia amostral?. **Nativa**, p. 1-7, 2019.

PETSCH, Carina; BUENO, Marina Brandt. Aplicação da técnica de NDVI em imagens Landsat para análise do efeito de geadas no município de Maringá – PR. **XVI Simpósio Brasileiro de Sensoriamento Remoto**, [S. l.], p. 1-7, 18 abr. 2013.

RAFAELLI, Débora Rosa. **Geoprocessamento para a avaliação do impacto de geadas na região cafeeira de Cornélio Procopio, PR**. 119 p., Botucatu, 2004.

RASHMI, S. *et al.* Spectral Angle Mapper Algorithm for Remote Sensing Image Classification. **International Journal of Innovative Science, Engineering & Technology**, p. 1-5, Disponível em: <https://www.ijiset.com/v1s4/IJSET_V1_I4_27.pdf>, jun. 2014.

RIBEIRO, Karém Cristina de Sousa *et al.* PREÇOS DO CAFÉ NO BRASIL: VARIÁVEIS PREDITIVAS NO MERCADO À VISTA E FUTURO. **Revista de Gestão**, São Paulo, v. 13, n. 1, p. 11-30, mar. 2006.

RICHARDS, John A. Remote Sensing Digital Image Analysis: An Introduction. **Springer**, p. 1-351, Disponível em: <DOI 10.1007/978-3-642-88087-2>, 1993.

RINALDI, Leonardo Alencar; ROSA, Helton Aparecido. Perfil temporal do índice de vegetação por diferença normalizada (NDVI) em uma área de pastagem. **Cultivando o saber**, v. 15, p. 1-9, 12 dez. 2022.

SAATH, Kleverton Clovis de Oliveira; FACHINELLO, Arlei Luiz. Crescimento da demanda Mundial de alimentos e restrições do fator terra no Brasil. **Revista de Economia e Sociologia Rural**, v. 56, n. 2, Disponível em: <<http://dx.doi.org/10.1590/1234-56781806-94790560201>>, p. 1-18, 17 mar. 2016.

SOARES, Daniel Veiga. **Sensoriamento remoto para mapear o potencial de produtividade do cafeeiro**. 2021.

SOUZA, Rafael de Brito *et al.* Mapeamento de áreas cafeeiras do sul de minas gerais – machado e três pontas. **VI Simpósio de Pesquisa dos Cafés do Brasil**, p. 1-6, 2009.

WORLD TRADE STATISTICAL REVIEW. **World Trade Organization**. Disponível em: <https://www.wto.org/english/res_e/publications_e/wtsr_2023_e.htm>, 138 p., 2023.

ANEXO

Tabela 4 – Tabela da matriz de confusão dos algoritmos de Máxima Verossimilhança, Mínima Distância e *Spectral Angle Mapper* (Continua).

Maxver 2019 Sem filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	2686	932	1	0	3619
Floresta	470	10036	34	0	10540
Outros usos	99	80	3444	261	3884
Usos agrop.	82	528	1609	4482	6701
Total	3337	11576	5088	4743	24744

Maxver 2019 Com filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	3697	797	1	0	4495
Floresta	60	10433	6	0	10499
Outros usos	1	13	3977	263	4254
Usos agrop.	1	223	669	5444	6337
Total	3759	11466	4653	5707	25585

Maxver 2023 Sem filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	10616	1825	108	101	12650
Floresta	30	9362	45	489	9926
Outros usos	0	78	4114	1714	5906
Usos agrop.	88	49	288	2303	2728
Total	10734	11314	4555	4607	31210

Maxver 2023 Com filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	10920	727	46	13	11706
Floresta	36	11054	21	315	11426
Outros usos	0	27	5007	968	6002
Usos agrop.	0	27	40	2790	2857
Total	10956	11835	5114	4086	31991

Tabela 4 – Tabela da matriz de confusão dos algoritmos de Máxima Verossimilhança, Mínima Distância e *Spectral Angle Mapper* (Continua).

MD 2019 Sem filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	1393	1634	57	28	3112
Floresta	729	9381	1	0	10111
Outros usos	9	244	3389	712	4354
Usos agrop.	1206	317	1641	4003	7167
Total	3337	11576	5088	4743	24744

MD 2019 Com filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	1625	1612	0	36	3273
Floresta	909	9498	0	62	10469
Outros usos	7	242	3565	1014	4828
Usos agrop.	1218	114	1088	4595	7015
Total	3759	11466	4653	5707	25585

MD 2023 Sem filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	7923	2026	138	888	10975
Floresta	2723	9159	453	181	12516
Outros usos	0	85	3647	2469	6201
Usos agrop.	88	44	317	1069	1518
Total	10734	11314	4555	4607	31210

MD 2023 Com filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	7958	2210	153	687	11008
Floresta	2934	9583	537	0	13054
Outros usos	0	13	4419	1915	6347
Usos agrop.	64	29	5	1484	1582
Total	10956	11835	5114	4086	31991

Tabela 4 – Tabela da matriz de confusão dos algoritmos de Máxima Verossimilhança, Mínima Distância e *Spectral Angle Mapper* (conclusão).

SAM 2019 Sem filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	1339	1788	0	0	3127
Floresta	445	7661	0	0	8106
Outros usos	3	23	2531	594	3151
Usos agrop.	1550	2104	2557	4149	10360
Total	3337	11576	5088	4743	24744

SAM 2019 Com filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	1943	1818	0	0	3761
Floresta	245	7680	0	0	7925
Outros usos	5	3	2814	754	3576
Usos agrop.	1566	1965	1839	4953	10323
Total	3759	11466	4653	5707	25585

SAM 2023 Sem filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	8171	711	69	581	9532
Floresta	2305	10417	32	178	12932
Outros usos	1	169	4181	3205	7556
Usos agrop.	257	17	273	643	1190
Total	10734	11314	4555	4607	31210

SAM 2023 Com filtro					
Valor Classificado	Café	Floresta	Outros	Agricultura	Total
Café	8233	580	26	538	9377
Floresta	2489	11178	3	17	13687
Outros usos	1	63	5085	2507	7656
Usos agrop.	233	14	0	1024	1271
Total	10956	11835	5114	4086	31991

Fonte: do autor (2024).

Tabela 5 – Tabela com Acurácia do Usuário, Erros de comissão, Acurácia do Produtor e Erros de omissão dos algoritmos de Máxima Verossimilhança, Mínima Distância e *Spectral Angle Mapper* (continua).

Maxver 2019 Sem filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
74,2194	25,7806	80,4915	19,5085
95,2182	4,7818	86,6966	13,3034
88,6715	11,3285	67,6887	32,3113
66,8855	33,1145	94,4972	5,5028

Maxver 2019 Com filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
82,2469	17,7531	98,3506	1,6494
99,3714	0,6286	90,9908	9,0092
93,4885	6,5115	85,4717	14,5283
85,9082	14,0918	95,3916	4,6084

Maxver 2023 Sem filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
83,9209	16,0791	98,9007	1,0993
94,3180	5,6820	82,7470	17,2530
69,6580	30,3420	90,3183	9,6817
84,4208	15,5792	49,9891	50,0109

Maxver 2023 Com filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
93,2855	6,7145	99,6714	0,3286
96,7443	3,2557	93,4009	6,5991
83,4222	16,5778	97,9077	2,0923
97,6549	2,3451	68,2819	31,7181

Tabela 5 – Tabela com Acurácia do Usuário, Erros de comissão, Acurácia do Produtor e Erros de omissão dos algoritmos de Máxima Verossimilhança, Mínima Distância e *Spectral Angle Mapper* (continua).

MD 2019 Sem filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
44,7622	55,2378	41,7441	58,2559
92,7801	7,2199	81,0384	18,9616
77,8365	22,1635	66,6077	33,3923
55,8532	44,1468	84,3981	15,6019

MD 2019 Com filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
49,6486	50,3514	43,2296	56,7704
90,7250	9,2750	82,8362	17,1638
73,8401	26,1599	76,6172	23,3828
65,5025	34,4975	80,5152	19,4848

MD 2023 Sem filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
72,1913	27,8087	73,8122	26,1878
73,1783	26,8217	80,9528	19,0472
58,8131	41,1869	80,0659	19,9341
70,4216	29,5784	23,2038	76,7962

MD 2023 Com filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
72,2929	27,7071	72,6360	27,3640
73,4104	26,5896	80,9717	19,0283
69,6234	30,3766	86,4099	13,5901
93,8053	6,1947	36,3191	63,6809

Tabela 5 – Tabela com Acurácia do Usuário, Erros de comissão, Acurácia do Produtor e Erros de omissão dos algoritmos de Máxima Verossimilhança, Mínima Distância e *Spectral Angle Mapper* (conclusão).

SAM 2019 Sem filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
42,8206	57,1794	40,1259	59,8741
94,5102	5,4898	66,1800	33,8200
80,3237	19,6763	49,7445	50,2555
40,0483	59,9517	87,4763	12,5237

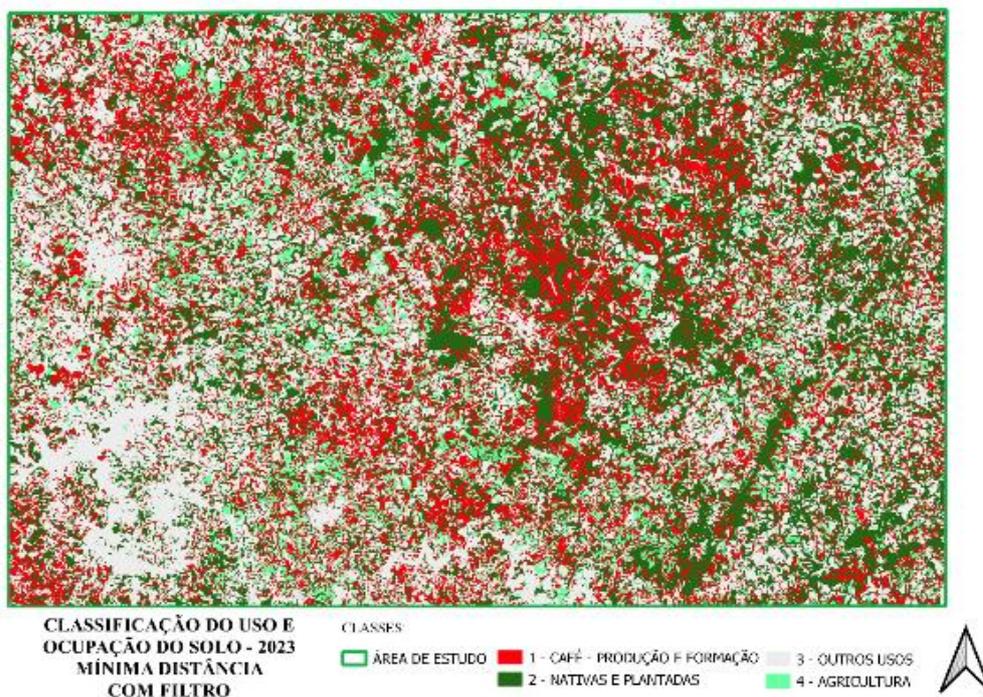
SAM 2019 Com filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
51,6618	48,3382	51,6893	48,3107
96,9085	3,0915	66,9806	33,0194
78,6913	21,3087	60,4771	39,5229
47,9802	52,0198	86,7882	13,2118

SAM 2023 Sem filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
85,7218	14,2782	76,1226	23,8774
80,5521	19,4479	92,0718	7,9282
55,3335	44,6665	91,7892	8,2108
54,0336	45,9664	13,9570	86,0430

SAM 2023 Com filtro			
Exatidão do usuário (%)	Erro de omissão (%)	Exatidão do produtor (%)	Erro de comissão (%)
87,7999	12,2001	75,1460	24,8540
81,6687	18,3313	94,4487	5,5513
66,4185	33,5815	99,4329	0,5671
80,5665	19,4335	25,0612	74,9388

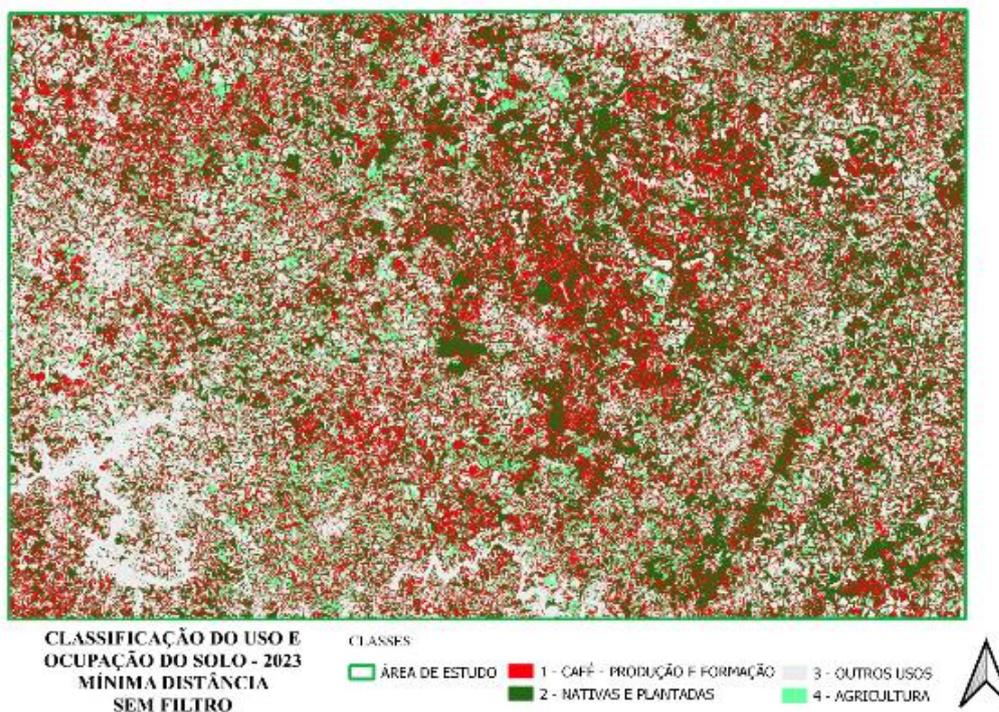
Fonte: do autor (2024).

Figura 8 – Mapa de uso e ocupação do solo do ano de 2023 obtido pelo método de Mínima Distância.



Fonte: do autor (2024).

Figura 9 – Mapa de uso e ocupação do solo do ano de 2023 obtido pelo método de Mínima Distância.



Fonte: do autor (2024).

Figura 10 – Mapa de uso e ocupação do solo do ano de 2019 obtido pelo método de Máxima Verossimilhança.

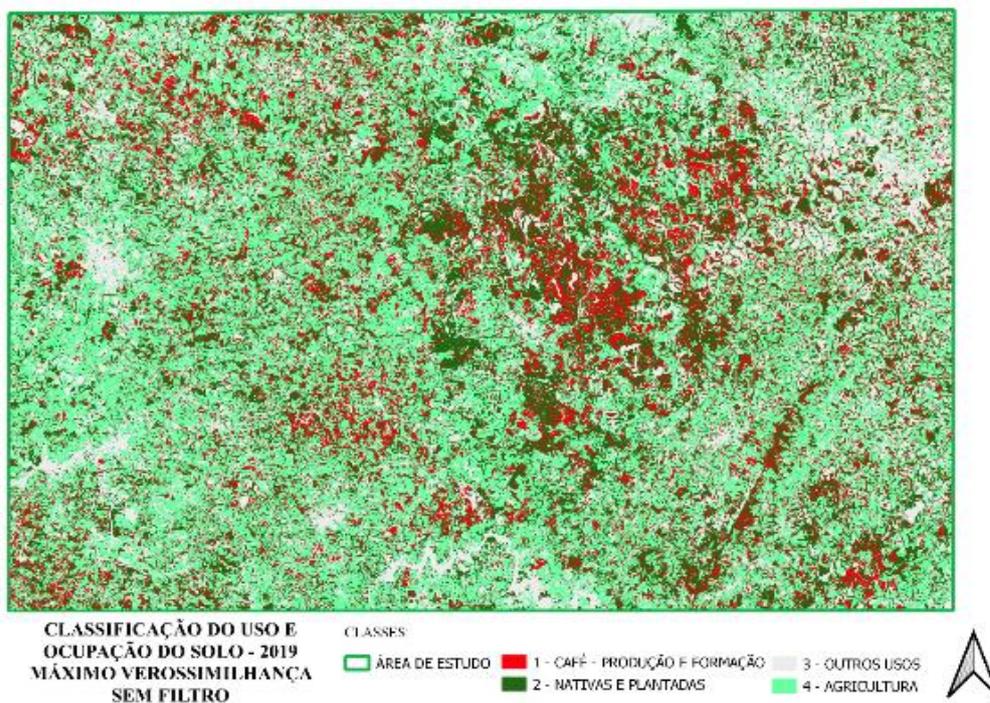


Figura 11 – Mapa de uso e ocupação do solo do ano de 2023 obtido pelo método de Máxima Verossimilhança.

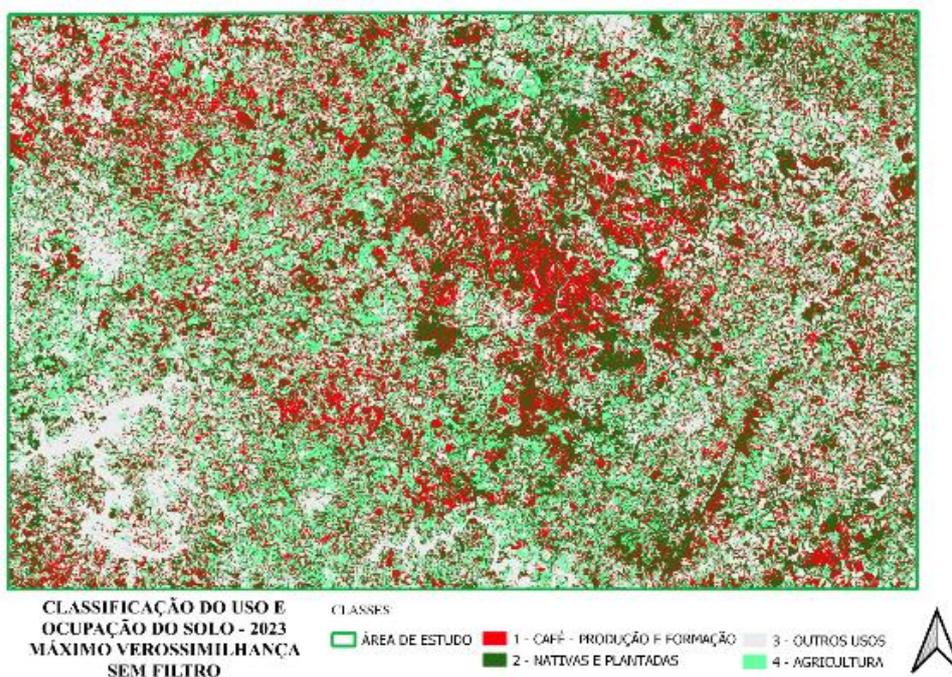
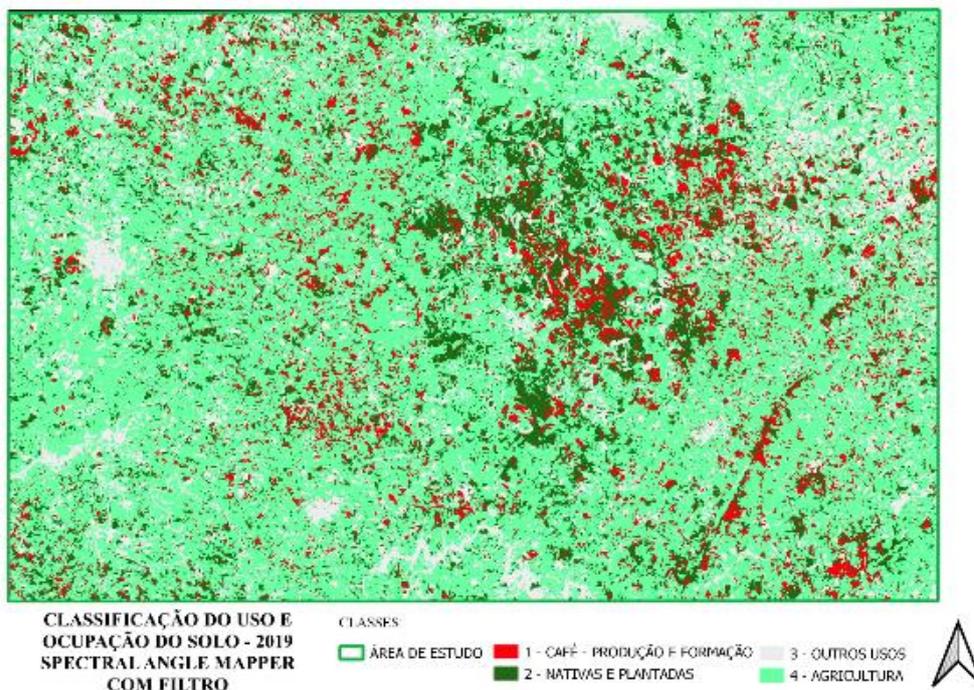
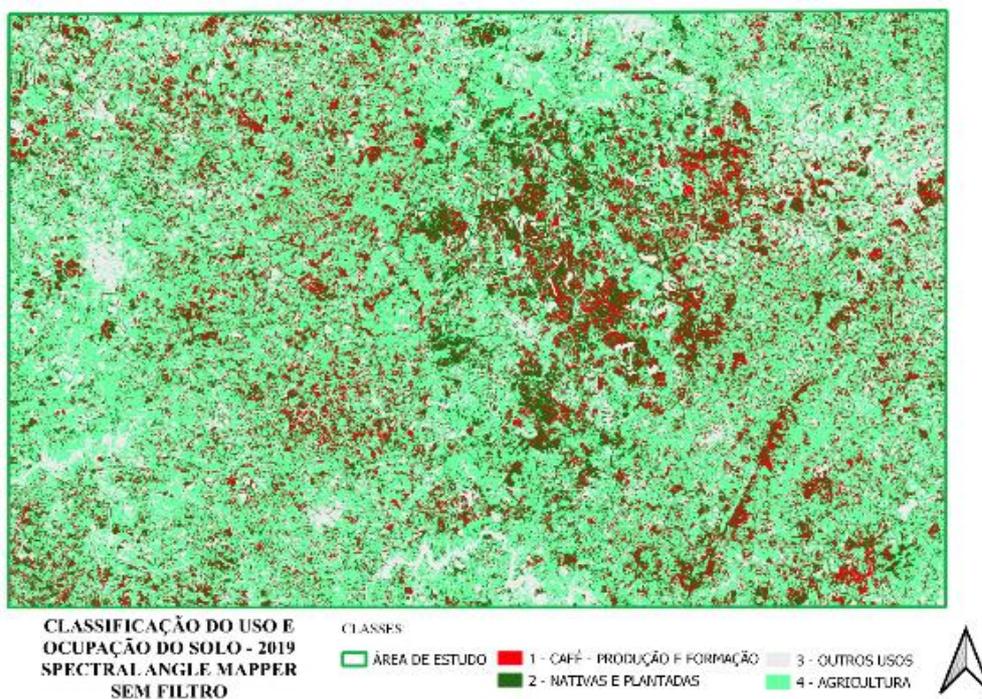


Figura 12 – Mapa de uso e ocupação do solo do ano de 2019 obtido pelo método *Spectral Angle Mapper*.



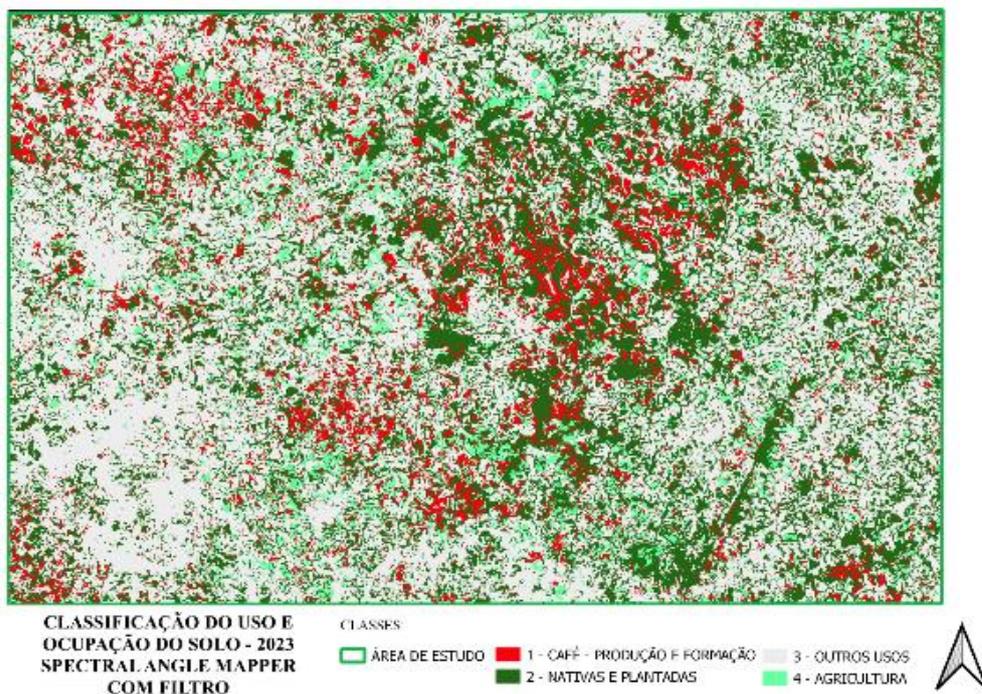
Fonte: do autor (2024).

Figura 13 – Mapa de uso e ocupação do solo do ano de 2019 obtido pelo método *Spectral Angle Mapper*.



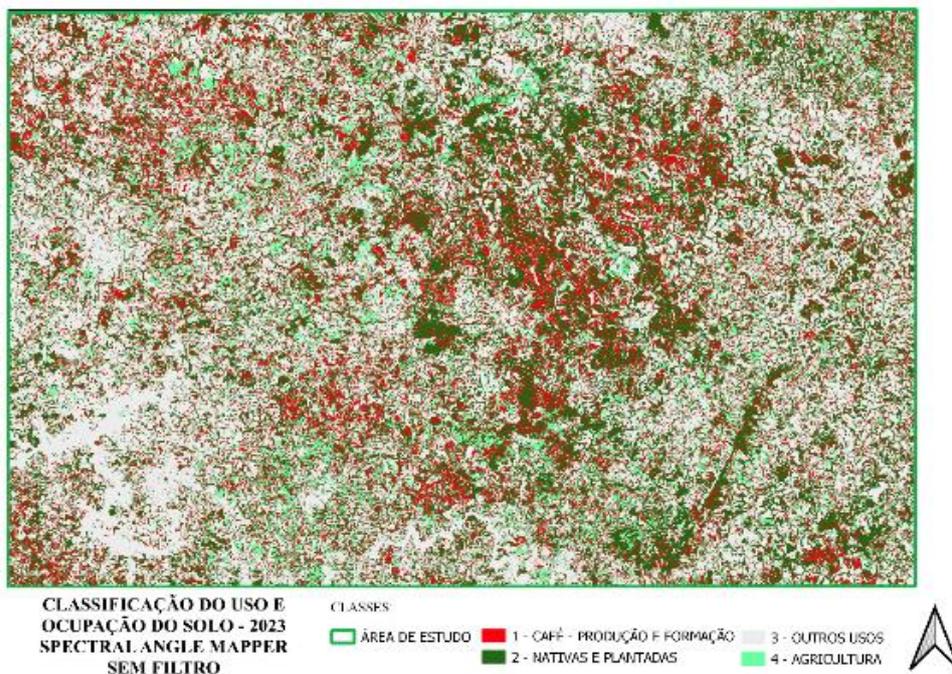
Fonte: do autor (2024).

Figura 14 – Mapa de uso e ocupação do solo do ano de 2023 obtido pelo método *Spectral Angle Mapper*.



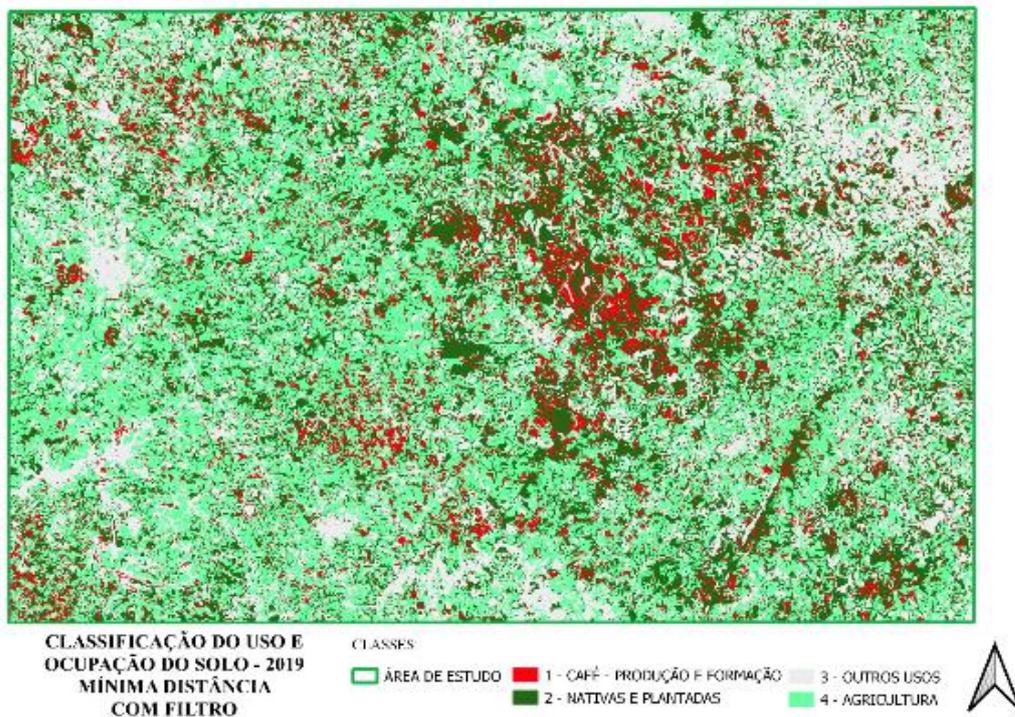
Fonte: do autor (2024).

Figura 15 – Mapa de uso e ocupação do solo do ano de 2023 obtido pelo método *Spectral Angle Mapper*.



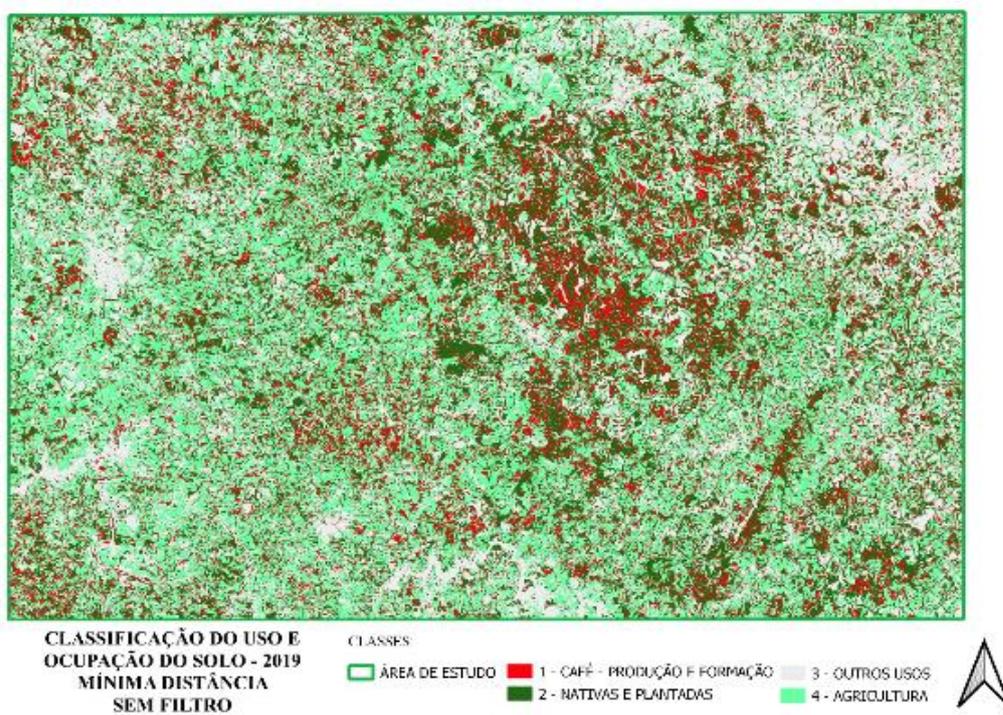
Fonte: do autor (2024).

Figura 16 – Mapa de uso e ocupação do solo do ano de 2019 obtido pelo método de Mínima Distância.



Fonte: do autor (2024).

Figura 17 – Mapa de uso e ocupação do solo do ano de 2019 obtido pelo método de Mínima Distância.



Fonte: do autor (2024).