

INSTITUTO FEDERAL DE MINAS GERAIS
CAMPUS SÃO JOÃO EVANGELISTA
BACHARELADO EM ENGENHARIA FLORESTAL

TAINARA MENDES RIBEIRO

**IDENTIFICAÇÃO DE ÁREAS DE SILVICULTURA EM
MINAS GERAIS POR MEIO DA MÁXIMA ENTROPIA EM
IMAGENS DO SENTINEL-2.**

SÃO JOÃO EVANGELISTA

2023

TAINARA MENDES RIBEIRO

**IDENTIFICAÇÃO DE ÁREAS DE SILVICULTURA EM
MINAS GERAIS POR MEIO DA MÁXIMA ENTROPIA EM
IMAGENS DO SENTINEL-2.**

Monografia apresentada ao Curso de Engenharia de Florestal do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais como parte dos requisitos para a obtenção do Grau de Engenharia Florestal.

Orientador(a): Dr. Jonathan da Rocha Miranda

SÃO JOÃO EVANGELISTA

2023

FICHA CATALOGRÁFICA

R484i Ribeiro, Tainara Mendes
Identificação de áreas de silvicultura em minas gerais por meio da máxima entropia em imagens do sentinel-2. / Tainara Mendes Ribeiro. – 2023.
27 f. : il.
Bibliografia f. 24-27

Trabalho de conclusão de curso (Bacharelado em Engenharia Florestal) - Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais, Câmpus São João Evangelista, 2023.

Orientação: Prof. Dr. Jonathan da Rocha Miranda.

1. Mapbioma. 2. Google Earth. 3. Colheita florestal. 4. Silvicultura. I. Tainara Mendes Ribeiro. II. Título.

CDD: 634



**MINISTERIO DA EDUCACAO
SECRETARIA DE EDUCACAO PROFISSIONAL E TECNOLOGICA
INSTITUTO FEDERAL DE EDUCACAO, CIENCIA E TECNOLOGIA DE MINAS GERAIS
CAMPUS SAO JOAO EVANGELISTA**

Avenida Prirneiro de Junho, 11º 1043 - Bairro Centro - Sao Joao Evangelista | Minas Gerais - CEP: 39.705-000 - (33) 3412-2989

CURSO DE BACHARELADO EM ENGENHARIA FLORESTAL

ATA DE DEFESA DE TRABALHO DE CONCLUSAO DE CURSO

IDENTIFICACAO

Discente:	Tainara Mendes Ribeiro
Matricula	0036671
Ano de ingresso	2017/1
Data de defesa:	06 de julho de 2023
Horario de defesa	8 horas e 30 minutos

INFORMACOES DO TRABALHO DE CONCLUSAO DE CURSO

IDENTIFICACAO DE AREAS DE SILVICULTURA EM MINAS GERAIS POR MEIO DA MAXIMA ENTROPIA EM IMAGENS DO SENTINEL 2
Titulo final (se alterado)

AVALIACAO

- () Aprovado sem correções
(x) Aprovado com correções
() Reprovado

BANCA EXAMINADORA

Composicao	Nome	Instituicao	Assinatura
Presidente:	Jonathan da Rocha Miranda	IFMG	
Membro(a) 1:	Valeria Santos Cavalcante	IFMG	
Membro(a) 2:	Mateus dos Reis	IFMG	

O sucesso nasce do
querer, da determinação e
persistência em se chegar a um
objetivo. Mesmo não atingindo
o alvo, quem busca e vence
obstáculos, no mínimo fará
coisas admiráveis.
(José de Alencar)

AGRADECIMENTOS

A Deus pela força e sabedoria para vencer todos os obstáculos.

À minha família por todo o apoio, incentivo e amor incondicional que me forneceram ao longo desta jornada. Vocês foram meu porto seguro nos momentos mais desafiadores, sempre me encorajando a seguir em frente e acreditar em minhas capacidades.

Aos meus amigos, vocês são uma parte especial da minha vida e da minha caminhada acadêmica. Obrigado por estarem ao meu lado, por ouvirem minhas ideias e por compartilharem suas opiniões. Vocês foram meu suporte social e emocional, proporcionando momentos de descontração e alívio no meio à pressão dos estudos. Cada risada, cada conselho e cada palavra de ânimo foram fundamentais para que eu pudesse continuar firme.

Ao meu orientador, Jonathan, agradeço imensamente por sua dedicação, paciência e orientação ao longo de todo o processo. Seu conhecimento e orientações foram fundamentais para o desenvolvimento deste trabalho.

À todos os professores do IFMG campus São João Evangelista, que ao longo do curso, compartilharam seus ensinamentos e experiências, para a minha formação acadêmica.

Aos meus colegas de curso que caminharam comigo nos últimos anos.

À todo IFMG campus São João Evangelista por todo conhecimento adquirido.

RESUMO

O mapeamento preciso da cobertura florestal é uma ferramenta inestimável na gestão e avaliação da silvicultura, oferecendo uma visão clara das áreas florestais e identificando regiões com potencial para exploração ou conservação. O Projeto Mapbioma, uma iniciativa brasileira, visa produzir mapas de uso cobertura do solo de alta resolução e acurácia. A integração de imagens do satélite Sentinel-2 ao projeto promete aprimorar os mapas ao incrementar a resolução espacial e expandir a habilidade de distinguir diferentes tipos de cobertura florestal. Esta pesquisa se propõe a explorar o uso das imagens do Sentinel-2 na identificação de áreas de silvicultura em Minas Gerais. Optou-se pelo período de 2019 a 2021 devido à disponibilidade de imagens corrigidas pelo efeito atmosférico. Foram selecionadas amostras das classes de silvicultura e não silvicultura com base no processamento do MapBioma. Estes dados foram então incorporados ao modelo de Máxima Entropia. Após a classificação, a acurácia do modelo foi avaliada e comparada com o levantamento de áreas pela Cenibra. Os resultados apontam para o alto potencial do método de Máxima Entropia na classificação de silvicultura, com uma assertividade de 85%. Em comparação com a Cenibra, a classificação pelo método de Máxima Entropia se mostrou mais realista do que o MapBioma, resultando em valores de 5.869, 4.648 e 312 hectares, respectivamente. O mapeamento produzido da silvicultura em Minas Gerais pode auxiliar no planejamento estratégico para a gestão desta cultura.

Palavras-chave: MapBioma, Google Earth Engine, Cenibra, colheita florestal, área efetiva.

ABSTRACT

Accurate mapping of forest cover is an invaluable tool in forestry management and assessment, offering a clear view of forest areas and identifying regions with potential for exploitation or conservation. The Mapbioma Project, a Brazilian initiative, aims to produce high resolution and accurate land cover use maps. The integration of Sentinel-2 satellite imagery into the project promises to improve the maps to increase spatial resolution and expand the ability to distinguish different types of forest cover. This research proposes to explore the use of Sentinel-2 images in the identification of forestry areas in Minas Gerais. The period from 2019 to 2021 was chosen due to the availability of images corrected for the atmospheric effect. Forestry and non-forestry classes were selected based on MapBioma processing. These data were then incorporated into the Maximum Entropy model. After the classification, the accuracy of the model was evaluated and revealed with the survey of areas by Cenibra. The results point to the high potential of the Maximum Entropy method in forestry classification, with an assertiveness of 85%. In comparison with Cenibra, classification using the Maximum Entropy method proved to be more realistic than MapBioma, generated in values of 5,869, 4,648 and 312 hectares, respectively. The mapping produced from forestry in Minas Gerais can help in strategic planning for the management of this culture.

Keywords: MapBioma, Google Earth Engine, Cenibra, forest harvest, effective area.

SUMÁRIO

1 INTRODUÇÃO	9
2 METODOLOGIA	10
2.1 Área de Estudo	10
2.2 Descrição dos Dados Utilizados	11
2.3 Pré-processamento	11
2.4 Composição do conjunto amostral	12
Fonte: Do autor (2023).....	13
2.5 Processamento e análise de dados.....	13
2.6 Estimativa da área colhida	14
2.7 Validação do modelo.....	14
3 RESULTADOS	15
3.1 Mapeamento de área efetiva	15
3.2 Mapeamento de área colhidas	17
3.3 Validação da classificação	21
5 CONCLUSÃO	23
REFERÊNCIAS	24
ANEXO A	26

1 INTRODUÇÃO

A silvicultura no Brasil desempenha um papel importante na economia e na sustentabilidade ambiental do país. Dedicada à produção, manejo e conservação de florestas comerciais e naturais, a silvicultura fornece uma fonte inestimável de recursos naturais e desempenha um papel crucial na manutenção do equilíbrio ecológico (LAURA *et al.*, 2021). Estima-se que a silvicultura contribua com cerca de 4% do PIB nacional e mais de 4 milhões de empregos diretos e indiretos, além de favorecer a conservação das florestas naturais através de seu manejo sustentável e da produção de madeira certificada (MACHADO *et al.*, 2014).

Em 2020, a produção do setor florestal brasileiro alcançou cerca de R\$ 116,6 bilhões, demonstrando sua relevância econômica. Minas Gerais destaca-se como líder no plantio florestal nacional (MENDES *et al.*, 2020). Este estado possui 1,39 milhões de hectares de florestas de eucalipto e 37,6 mil hectares de florestas de pinus (ANUAL, 2022).

O uso do mapeamento florestal é uma prática relevante para avaliar e gerenciar de forma sustentável a floresta (ASNER *et al.*, 2002). Por meio da elaboração de mapas, é possível visualizar a estrutura florestal, planejar cortes seletivos e monitorar a dinâmica da floresta, entre outras ações (CLARK; KELLNER, 2012; MITCHARD *et al.*, 2012).

O MapBiomias é um projeto que produz mapas de uso e cobertura da terra para todo o Brasil, por meio de imagens de satélite Landsat e técnicas de aprendizado de máquina (SOUZA; AZEVEDO, 2017). Esses dados têm sido empregados em trabalhos científicos, tais como avaliar a cobertura vegetal e o uso e ocupação da terra na região semiárida brasileira (DA SILVA *et al.*, 2022), caracterizar a mudança no uso e cobertura da terra (BANCHERO *et al.*, 2020).

O uso do MapBioma pode apresentar limitações, como a resolução espacial, a precisão da classificação, e a dificuldade em distinguir plantios florestais de diferentes idades ou em identificar áreas recentemente desmatadas ou em regeneração. Estes problemas tendem a ser atenuado se incorporado imagens de satélite de maior resolução em detrimento do Landsat. Neste sentido as imagens do Sentinel-2, com resolução espacial de 10 metros, apresentam maior precisão que as do Landsat, cuja resolução é de 30 metros, permitindo um detalhamento mais acurado da cobertura florestal e do uso da terra. Contudo, o processamento de imagens de alta resolução do Sentinel-2 demanda maior capacidade de processamento, exigindo uma plataforma que suporte grandes volumes de dados com custos operacionais reduzidos, tal como a Google Earth Engine (GEE) (GORELICK *et al.*, 2017).

A Google Earth Engine (GEE) é uma plataforma para processamento e análise de dados geoespaciais em larga escala criada pelo Google. Ela provê acesso a um vasto acervo de imagens

de satélite e outras fontes de dados geoespaciais, além de ferramentas de processamento e análise baseadas na nuvem. Esta plataforma se revela como uma ferramenta valiosa para projetos que envolvem mapeamento e análise de dados geográficos, inclusive no mapeamento de florestas plantadas (GORELICK *et al.*, 2017). Além disso, oferece recursos robustos para processamento e análise desses dados, incluindo algoritmos de classificação de imagens, modelos de terreno e análises de mudanças na cobertura da terra, permitindo a realização de projetos de grande escala em um curto período de tempo (VAEZA *et al.*, 2010).

O uso de ferramentas avançadas para processamento de dados de satélite permite a aplicação de técnicas de classificação de imagens com maior resolução espacial, como as do Sentinel-2. Em situações onde se busca a classificação de uma única classe, como a silvicultura, a Google Earth Engine (GEE) disponibiliza algoritmos de classificação binária, incluindo o de Máxima Entropia. Este algoritmo possui a vantagem de destacar uma classe específica, diminuindo a confusão com outras classes. Tal precisão é possível porque o método considera as características espectrais dos pixels, permitindo uma diferenciação mais acurada entre as classes (PRESTON *et al.*, 2023; VENTER; SYDENHAM, 2021).

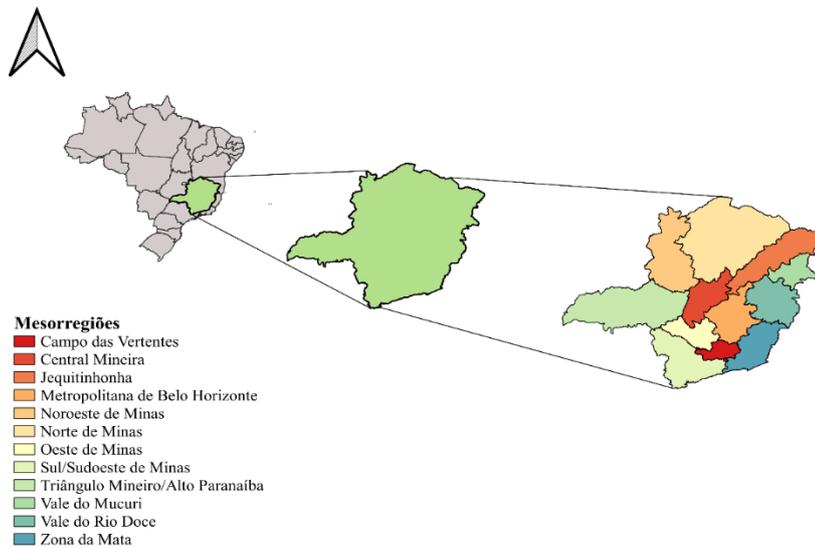
Deste modo, este trabalho tem como objetivo aprimorar o produto Mapbiomas, com ênfase na classe de silvicultura, através da aplicação da técnica de Máxima Entropia em imagens do Sentinel-2. A Máxima Entropia será utilizada para aumentar a precisão e a acurácia da classificação da silvicultura, com vistas à produção de um mapa mais confiável e preciso desta classe. A combinação do Sentinel-2 com a Google Earth Engine oferece uma abordagem poderosa para o mapeamento florestal, permitindo a obtenção de mapas de alta resolução e precisão.

2 METODOLOGIA

2.1 Área de Estudo

Minas Gerais, líder de plantio florestal nacional (MENDES *et al.*, 2020), localizado na região sudeste do Brasil, desempenha um papel crucial no setor silvícola nacional (Figura 1). O Estado abrange três principais tipos de climas: tropical, subtropical e semiárido, conforme a classificação climática de Köppen (MARTINS *et al.*, 2018). Esta diversidade climática favorece a produção florestal, permitindo o cultivo de uma ampla variedade de espécies arbóreas, tanto nativas quanto exóticas.

Figura 1: Visualização espacial do Estado de Minas Gerais e suas mesorregiões



Fonte: Do autor (2023).

2.2 Descrição dos Dados Utilizados

- Dados do Sentinel-2: Estes dados fornecem informações espectrais com resolução espacial variando de 10 a 60 metros e resolução espectral em 13 bandas no visível, infravermelho próximo e infravermelho de ondas curtas (PHIRI *et al.*, 2020).
- Dados do MapBiomas: Para este trabalho, foram aplicados dados de mapeamento de uso e cobertura da terra do projeto MapBiomas, que realizou mapeamentos baseados em imagens de satélite Landsat de 1985 a 2021. O mapeamento do MapBiomas categoriza as áreas em diversas classes de uso da terra, incluindo a silvicultura (SOUZA JUNIOR; AZEVEDO, 2017).
- Dados de limite municipal do IBGE: Foram utilizados dados do Instituto Brasileiro de Geografia e Estatística (IBGE) para determinar os limites dos municípios de Minas Gerais. Essas informações foram empregadas para delimitar a área de estudo e identificar as propriedades rurais que serão analisadas.
- Dados do Plano de Manejo da CENIBRA: Empregados para comparação com os resultados obtidos pela MaxEnt e Mapbiomas.

2.3 Pré-processamento

O intervalo de tempo analisado neste estudo abrange de 2019 a 2021, escolhido devido à disponibilidade de imagens corrigidas atmosféricamente do Sentinel-2 no catálogo do Google

Earth Engine (GEE). Estas correções são necessárias pois as condições atmosféricas como a presença de nuvens, aerossóis e gases podem interferir na qualidade das imagens, gerando erros e atenuando o sinal do espectro eletromagnético (VERMOTE *et al.*, 2016). Deste modo, foi empregado o modelo de transferência radiativa SEN2COR, que simula a propagação da luz na atmosfera e calcula a quantidade de luz que atinge a superfície (MAIN-KNORN *et al.*, 2017). Esse modelo leva em consideração as condições atmosféricas e o ângulo de visão do satélite, fornecendo uma correção precisa e confiável (RICHTER, 1996).

Foi desenvolvido uma rotina no GEE para a obtenção de imagens do Sentinel-2 que cobrissem todo o território de Minas Gerais com mínimo possível de nuvens. Esta rotina selecionou apenas imagens com uma cobertura de nuvens inferior a 20%. Para assegurar a continuidade das imagens ao longo do ano, os valores medianos de cada banda espectral foram utilizados para compor uma imagem anual, cobrindo o período de janeiro a dezembro. Esta estratégia possibilitou a obtenção de uma cobertura completa e consistente do estado ao longo do tempo.

Após a aquisição das imagens anuais, calculou-se o Índice de Vegetação por Diferença Normalizada (NDVI). Este índice é uma métrica que avalia a quantidade e a qualidade da vegetação na superfície terrestre, utilizando informações das diferenças espectrais capturadas por sensores remotos (HUETE *et al.*, 1997).

O cálculo do NDVI foi realizado a partir da diferença entre as reflectâncias na banda infravermelha (NIR) e na banda vermelha (RED) da imagem, normalizada pela soma das reflectâncias dessas duas bandas (Equação 1).

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (1),$$

em que: NIR corresponde a luz refletida na faixa infravermelha e RED corresponde a luz refletida na faixa vermelha.

2.4 Composição do conjunto amostral

A composição do conjunto amostral consistiu na transformação da imagem do uso e ocupação do solo oriundo do MapBioma em polígonos e na extração dos respectivos centróides. Foi estabelecido um limiar de NDVI de 0,6 para identificar áreas de vegetação na classe de silvicultura, sendo assim foi considerado como classe de presença da cultura aquela no qual foi classificada previamente no MapBioma e com vegetação presente. Após a aplicação do critério

NDVI, foram selecionados aleatoriamente aproximadamente 300 mil pontos de centroides pertencentes à classe de silvicultura para constituir o conjunto de amostras.

Para a classe sem silvicultura, selecionou-se um conjunto aleatório de pontos com um espaçamento mínimo de 10 metros entre si, dentro dos limites do Estado de Minas Gerais, em quantidade igual à da classe de silvicultura, totalizando cerca de 300 mil pontos (Tabela 1). Para garantir a homogeneidade das amostras, a classe de uso do solo correspondente foi extraída do MapBioma e assim se assegurou que nenhum ponto selecionado estava contido na a classe de silvicultura.

Tabela 1: Distribuição das amostras em conjunto treinamento e validação para as classes de uso e ocupação do solo.

Uso do solo	Treinamento			Validação		
	2019	2020	2021	2019	2020	2021
Formação Florestal	79.390	68.990	67.430	7.641	7.195	7.436
Formação Savânica	52.580	51.930	30.720	4.889	5.141	4.997
Silvicultura	270.000	270.000	270.000	27.000	27.000	27.000
Área Pantanosa	4.410	4.410	4.480	567	658	473
Formação Campestre	14.610	14.480	14.270	1.785	1.698	1.578
Pastagem	51.570	30.640	31.420	3.278	3.546	3.289
Cana	2.720	2.610	2.620	569	632	754
Mosaico de Usos	23.460	54.200	77.100	8.165	8.213	7.995
Área Urbanizada	1.450	1.460	1.550	270	113	259
Áreas não Vegetadas	1.120	1.110	1.140	330	450	338
Afloramento Rochoso	3.200	3.150	3.120	368	289	372
Mineração	450	470	450	89	179	210
Rio	2.210	2.350	2.100	573	547	671
Soja	10.853	13.700	13.570	1.698	1.445	1.258
Lavouras Temporárias	7.380	6.620	7.150	987	945	986
Café	13.457	12.650	11.650	1.357	1.524	1.785
Citrus	890	950	950	245	278	341
Lavouras Perenes	250	280	280	189	147	258
Total	540.000	540.000	540.000	60.000	60.000	60.000

Fonte: Do autor (2023)

2.5 Processamento e análise de dados

De posse do conjunto amostral previamente estabelecido, foi utilizado do algoritmo de aprendizado supervisionado Máxima Entropia, com o intuito de classificar imagens do Sentinel-

2, focando especificamente na detecção de áreas de silvicultura. Este algoritmo, conhecido como Maxent, tem como propósito estimar a distribuição mais verossímil num contexto geográfico uniforme, contribuindo para a identificação de locais onde ocorre a variável dependente, no caso, a silvicultura (PEARSON *et al.*, 2007). O método envolve a análise de probabilidade da distribuição de Poisson, sendo que o modelo linear generalizado de Bernoulli foi aplicado na função de ligação log-log, conforme sugere Fithian *et al.* (2015), devido à sua adequação na estimação da probabilidade de ocorrência.

Neste cenário, a presença ou ausência de silvicultura foi considerada como variável dependente, enquanto os valores medianos anuais de reflectância das imagens do Sentinel-2 foram tratados como variáveis independentes. Após o treinamento, o modelo gerou uma probabilidade associada a cada ponto do conjunto amostral. Para a determinação da classe de silvicultura, utilizou-se um limiar de separação calculado no intervalo de confiança de 95% de uma distribuição normal. A partir dessa abordagem, foi possível distinguir áreas de ocorrência de silvicultura, aplicando o valor de limiar para a segmentação das imagens e a subsequente reclassificação para a classe de silvicultura.

2.6 Estimativa da área colhida

Identificação subsequente de área florestal pelo modelo MaxEnt, procedeu-se ao cálculo da área colhida. Para tal, foram contrastadas imagens de silvicultura de diferentes anos, concebendo como área colhida aquelas regiões que exibiam a presença de silvicultura em um determinado ano e sua ausência no ano subsequente. Tal procedimento envolveu a realização de uma operação diferencial entre as imagens, e os valores positivos decorrentes dessa diferença foram reconhecidos como a área efetivamente colhida.

2.7 Validação do modelo

A fim de avaliar a eficácia do modelo de classificação aplicado, recorreu-se à utilização de métricas convencionais de classificação, como acurácia global, acurácia balanceada, precisão e recall (Equação 2,3 e 4). Tais métricas oferecem insights relevantes acerca da habilidade do modelo em corretamente classificar as amostras em suas respectivas classes.

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (2),$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3),$$

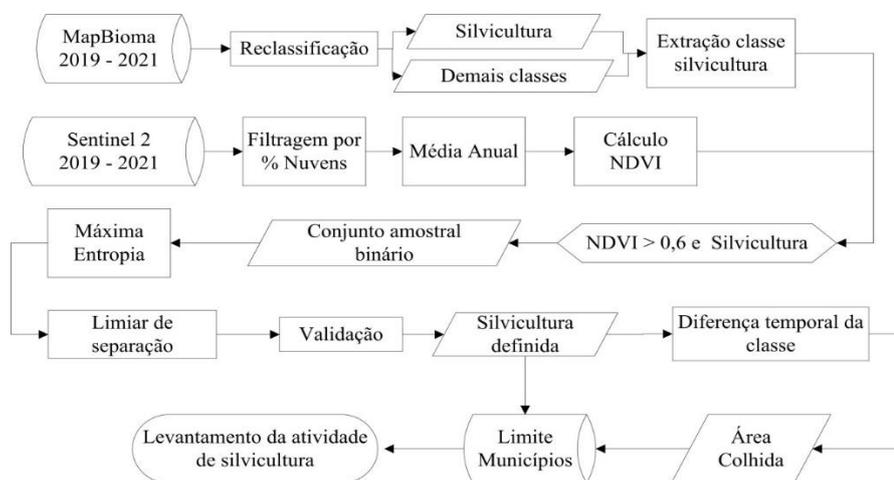
$$\text{Recall} = \frac{VP}{VP + FN} \quad (4),$$

em que: VP corresponde ao verdadeiro positivo; VN corresponde ao verdadeiro negativo; FP corresponde ao falso positivo e FN corresponde ao falso negativo.

A acurácia global representa a proporção de acertos do modelo em comparação com o número total de amostras analisadas. A acurácia balanceada, por sua vez, leva em conta o potencial desbalanceamento entre as classes na base de dados, avaliando a eficácia do modelo em classificar corretamente as amostras de cada classe. A precisão se refere à proporção de verdadeiros positivos em relação ao somatório de verdadeiros positivos e falsos positivos. Por fim, o recall quantifica a proporção de verdadeiros positivos comparativamente ao somatório de verdadeiros positivos e falsos negativos.

Em geral se empregou esta metodologia para realizar a incorporação de imagens de alta resolução do satélite Sentinel-2 (Figura 2), e da aplicação da técnica de MaxEnt, ao Projeto Mapbioma.

Figura 2: Fluxograma do processamento dos dados aplicado para o levantamento da silvicultura.



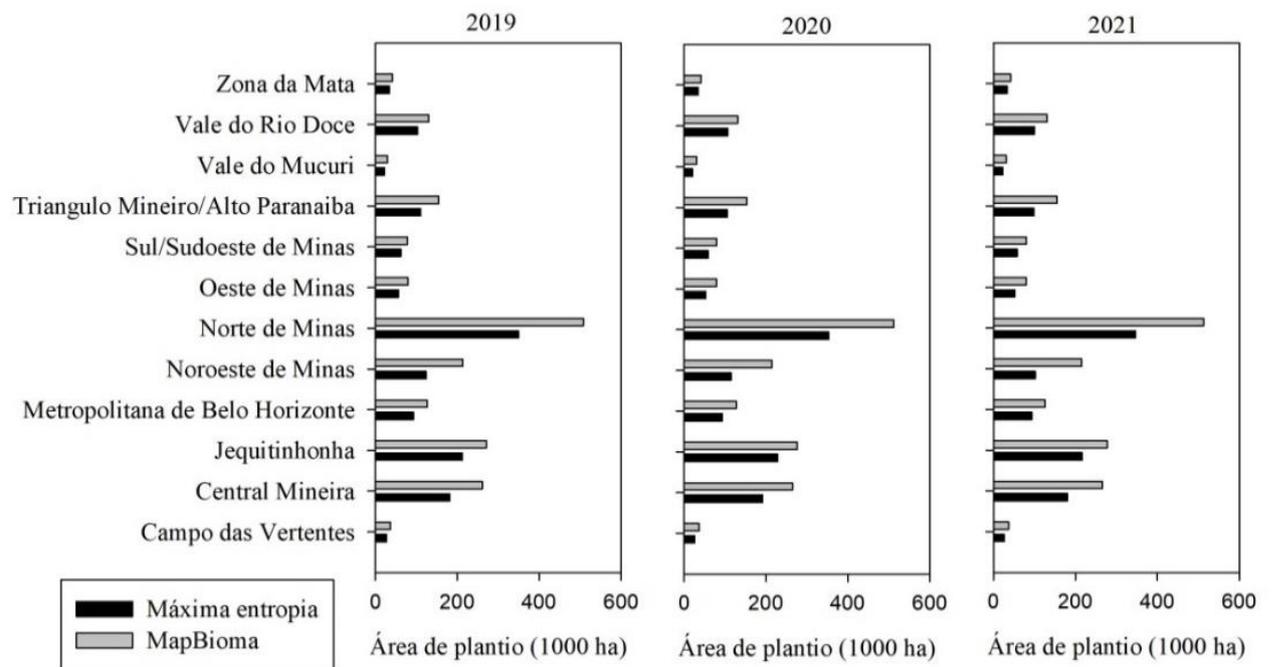
Fonte: Do autor (2023)

3 RESULTADOS

3.1 Mapeamento de área efetiva

Em todas as mesorregiões de Minas Gerais, a área mapeada de silvicultura pelo MapBioma foi superior em relação ao mapeamento pela MaxEnt (Figura 3). Ao comparar os anos, observou-se uma pequena variação na área plantada, refletindo uma baixa expansão da atividade, mas uma manutenção da área efetiva, considerando o ciclo da cultura.

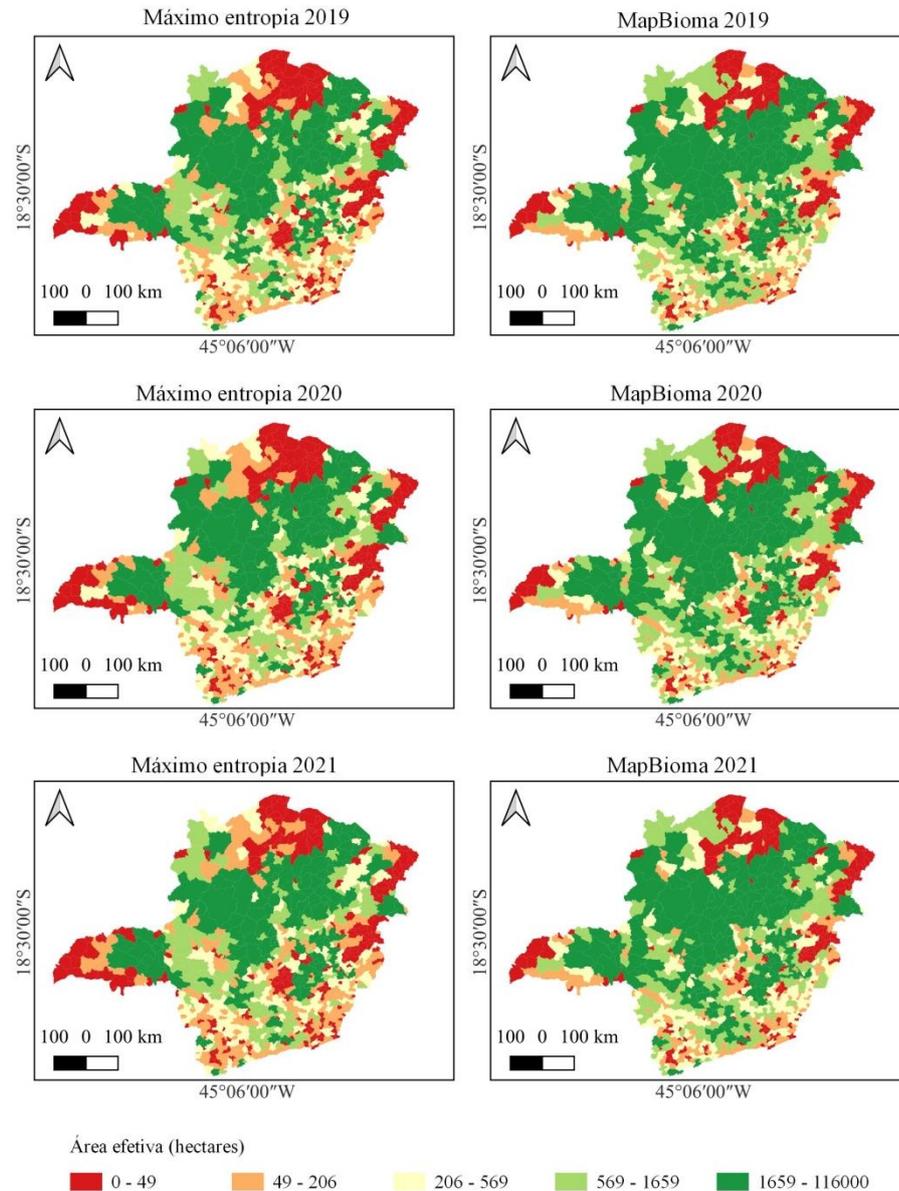
Figura 3: Levantamento pelo método da Máxima entropia e o MapBioma para área de plantio efetivo de silvicultura em diferentes Mesorregião do Estado de Minas Gerais



Fonte: Do autor (2023).

Na espacialização dos dados de área efetiva por município, houve uma maior divergência entre os locais cuja área foi inferior a 500 hectares (Figura 4). Devido ao recall do MapBioma ser inferior à classificação pela MaxEnt, pode estar ocorrendo uma inclusão de classes não pertencentes à silvicultura, resultando na superestimação da classe. Nesse sentido, é recomendado uma revisão da metodologia de classificação utilizada pelo MapBioma em relação à área mínima mapeável, a fim de garantir a precisão e confiabilidade dos resultados.

Figura 4: Espacialização das áreas de plantio efetivas pelo método de Máxima entropia e o MapBioma para os municípios de Minas Gerais.



Fonte: Do autor (2023)

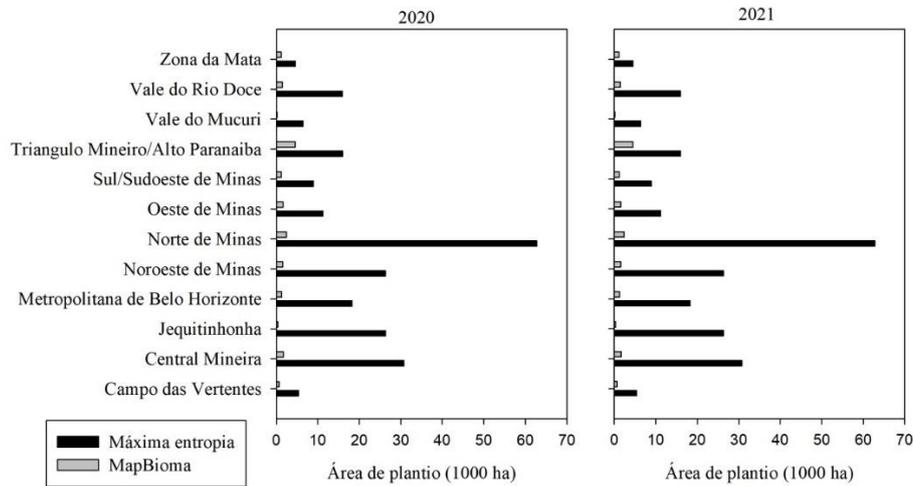
Para pequenos fragmentos de área, foi perceptível a inclusão do MapBioma para silvicultura. No entanto, ao confrontar com a classificação da MaxEnt, este comportamento não foi observado (Anexo A). Este fenômeno, também conhecido como salpicamento, refere-se aos pixels com comportamento espectral semelhante à classe determinada, mas com a menor área a ser considerada.

3.2 Mapeamento de área colhidas

Em relação à colheita, ocorre o inverso em relação à área plantada. Neste caso, o MapBioma apresenta uma área inferior em comparação ao mapeamento pela MaxEnt(Figura 5).

Considerando as atividades econômicas da silvicultura, é esperado que houvesse uma área considerável de colheita, que no caso do MapBioma não reflete a realidade do setor.

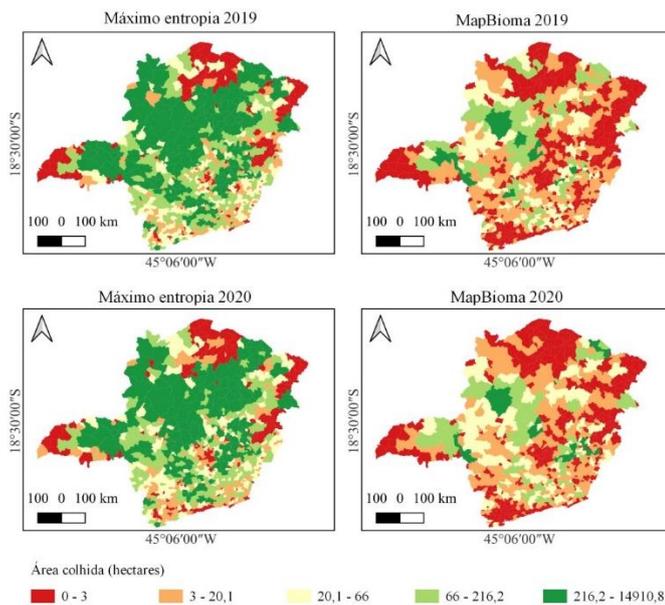
Figura 5: Levantamento pelo método da Máxima entropia e o MapBioma para área colhida plantio de silvicultura em diferentes Mesorregião do Estado de Minas Gerais



Fonte: Do autor (2023)

Com relação à distribuição espacial por município, o MapBioma indica uma baixa área colhida para a mesma região onde houve grandes áreas de plantio efetivo (Figura 6). Esta informação não condiz com a realidade visto que para municípios onde prevalece o uso da silvicultura para fins energéticos como o caso de Itamarandiba e Carbonita era esperado uma área mínima a ser colhida e no entanto foi observado uma área em torno de 27 hectares para uma região de plantio efetivo de 40.974 hectares.

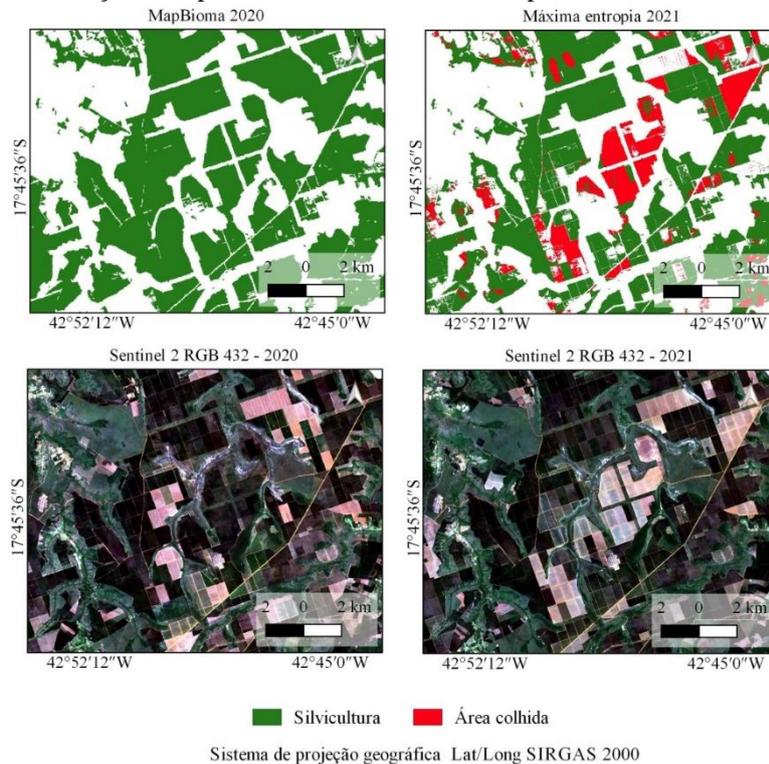
Figura 6: Espacialização de silvicultura colhida pelo método de Máxima entropia e o MapBioma para os municípios de Minas Gerais.



Fonte: Do autor (2023)

Ao comparar a área colhida com relação a área efetiva, o Mapbioma não indica que houve a supressa da vegetação ao se confrontar com as imagens do Sentinel-2 (Figura 7). No caso para a mesma área está supressão foi detectada no mapeamento pela MaxEnt o que demonstra a sensibilidade do modelo em mapear apenas os locais onde de fato há presença da silvicultura.

Figura 7: Detalhe na detecção na supressão de área de silvicultura pelo método da Máxima entropia e o MapBioma

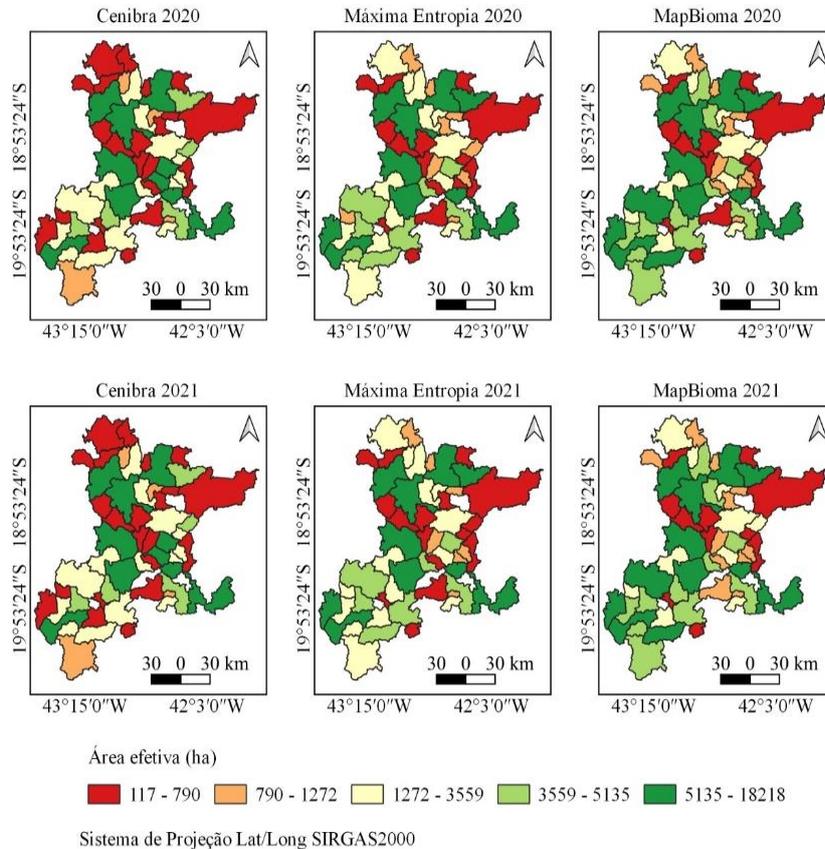


Fonte: Do autor (2023)

A Cenibra, é uma empresa que atua em 54 municípios de Minas Gerais, ela divulga anualmente em seu plano de manejo a área efetiva de eucalipto para cada município.

Os resultados apontam que a área mapeada pelo MapBioma é significativamente superior à área reportada pela Cenibra. Por outro lado, a área mapeada pela MaxEnt apresentou um valor mais próximo ao reportado pela Cenibra, embora ainda seja superior (Figura 8).

Figura 8: Espacialização das área de plantio efetivo de silvicultura declarados pela Cenibra e o detectado pelo método da Máxima entropia e o MapBioma



Fonte: Do autor (2023)

Esta diferença superior da MaxEnt pode ser justificada pelo fato de que nem todas as áreas de eucalipto na região são de propriedade da Cenibra. Portanto, é possível que a MaxEnt esteja mapeando áreas de eucalipto que não estão incluídas nos dados da Cenibra, resultando em uma estimativa de área maior.

Esses resultados sugerem que o mapeamento pela MaxEnt pode fornecer uma estimativa mais precisa da área de eucalipto na região, em comparação com o MapBioma (Tabela 2).

Tabela 2: Comparativo da área efetiva e colhida de silvicultura entre o declarado pela Cenibra, máxima entropia e o MapBioma.

Fonte	Área efetiva (ha)		Área colhida (ha)	
	2020	2021	2020	2021
Cenibra	131.001	130.892	16.678	15.896
MapBioma	189.601	186.839	2.284	5.312
Máxima Entropia	160.254	154.331	22.558	24.648

Fonte: Do autor (2023)

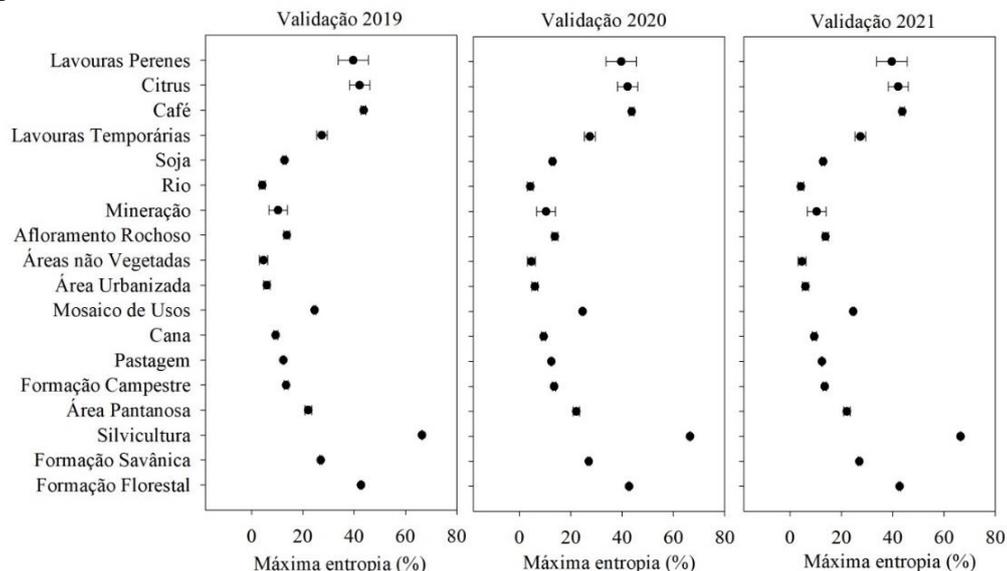
Esses resultados sugerem que a MaxEnt pode fornecer uma estimativa mais precisa tanto da área efetiva quanto da área colhida de eucalipto na região, em comparação com o MapBioma.

No entanto, é importante considerar que ambas as técnicas de mapeamento podem ter suas limitações e que os resultados devem ser interpretados à luz dessas limitações.

3.3 Validação da classificação

A análise utilizando a técnica de MaxEnt destacou a predominância da silvicultura em relação às demais classes presentes na área de estudo, apresentando um valor distinto de aproximadamente 60% (Figura 9). É importante salientar que, ao considerar o intervalo de confiança, todas as outras classes exibiram valores abaixo deste limiar.

Figura 9: Valores médio de entropia com intervalo de confiança a 95% para diferentes classes de uso e ocupação do solo nos pontos validados



Fonte: Do autor (2023).

Os resultados obtidos neste estudo, que demonstraram consistência durante o período de 2019 a 2021, reforçam a eficácia do método de MaxEnt como uma ferramenta valiosa para a identificação e quantificação da silvicultura em uma área de interesse específico. Em relação às métricas de avaliação adquiridas na classificação da silvicultura, os resultados foram notáveis, com precisão, acurácia e recall todos ultrapassando 0,8 para todos os anos analisados (Tabela 3). Este desempenho superou o encontrado pelo MapBiomass, que registrou uma precisão de 92,9% e um recall de 52,98% (SOUZA *et al.*, 2020).

Tabela 3: Métricas de Avaliação

Métrica de avaliação	2019	2020	2021
Acurácia Global	87,1	86,7	85,7
Precisão	91,5	91,4	89,5
Recall	81,9	81,1	81,0

Fonte: Do autor (2023)

Tabela 4: Métricas de Avaliação Mapbiomas

Métrica de avaliação	
Acurácia Global	0,52%
Precisão	92,90%
Recall	52,98%

Fonte: SOUZA *et al.* (2020)

4 DISCUSSÃO

A técnica de Máxima Entropia tem sido amplamente utilizada para aprimorar a precisão e a acurácia da classificação em imagens de satélite, como as fornecidas pelo Sentinel-2. Esta abordagem tem se mostrado particularmente eficaz na produção de mapas mais confiáveis e precisos desta classe de cobertura do solo.

No estudo conduzido por Marcial e Santillan (2020), a eficácia do mapeamento da Falcata (*Paraserianthes falcataria*) foi avaliada usando imagens do Sentinel-2. Foi demonstrado que o MaxEnt poderia oferecer uma precisão de classificação variando de 89,41% a 92,84%. Por outro lado, Chiang e Valdez (2019) utilizaram imagens de satélite Landsat e um Modelo Digital de Elevação (DEM) com um algoritmo de Entropia Máxima. A pesquisa apontou que a abordagem combinada resultou em uma precisão geral e coeficiente kappa superiores.

Em relação ao MapBioma, que utiliza imagens do sensor Landsat em seu processo de mapeamento, é importante destacar que essas imagens não são corrigidas dos efeitos atmosféricos conforme Souza *et al.* (2020). Isso pode afetar a precisão do mapeamento, especialmente em áreas com alta variabilidade atmosférica. Por outro lado, os dados obtidos a partir do levantamento realizado com a MaxEnt foram corrigidos os efeitos atmosféricos além de possuir uma resolução espacial superior em comparação com o Landsat.

As principais divergências podem estar atreladas ao efeito, envolve o desafio da mistura espectral e de salpicamento. O MapBioma, que utilizou imagens do sensor Landsat, aplicou um filtro espacial que segmenta e indexa as classes de cada coleção em regiões contíguas. Este filtro tem como objetivo reduzir o efeito de salpicamento e melhorar a precisão do mapeamento conforme Souza *et al.* (2020). No entanto, mesmo com este filtro, ainda foi possível notar a mistura espectral entre eucalipto e mata nativa.

No entanto, é importante notar que, embora a MaxEnt e o Sentinel-2 possam oferecer vantagens em termos de precisão e resolução, eles também podem exigir mais recursos

computacionais e uma maior complexidade na análise em comparação com outras técnicas, como as utilizadas pelo MapBioma (LIM *et al.*, 2019). Portanto, a escolha da técnica de mapeamento deve levar em consideração tanto a precisão desejada quanto os recursos disponíveis.

A detecção de áreas de colheita é uma tarefa desafiadora no mapeamento da silvicultura, especialmente em regiões com alta variabilidade de cobertura do solo e uso da terra, como Minas Gerais. O MapBiomas, que utiliza imagens do sensor Landsat e aplica um filtro temporal para lidar com transições fenológicas e de uso da terra específicas (SOUZA *et al.* 2020). Segundo os autores, este filtro tem como objetivo corrigir a transição entre classes de 3 a 5 anos, o que pode explicar a não ocorrência de colheita detectada pelo MapBiomas.

Por outro lado, o método da MaxEnt, que utiliza imagens do sensor Sentinel-2, tem se mostrado eficaz na detecção de áreas de colheita levando em consideração aos valores da Cenibra. Este método pode ser particularmente útil em situações onde a área de colheita varia significativamente de ano para ano, como é o caso da silvicultura de eucalipto. A Máxima Entropia é capaz de capturar essas variações sutis, o que pode resultar em uma estimativa mais precisa da área de colheita (PEARSON *et al.*, 2007).

No entanto, é importante notar que a Máxima Entropia pode superestimar a área de colheita em alguns casos. Isso pode ser devido ao fato de que a Máxima Entropia é uma técnica que busca maximizar a entropia de uma distribuição de probabilidade, o que pode levar a uma maior sensibilidade à variabilidade dentro de uma classe de cobertura do solo (DELALAY *et al.*, 2019). Portanto, é possível que a Máxima Entropia esteja detectando áreas de eucalipto que não são destinadas à colheita, o que pode resultar em uma estimativa superior da área de colheita em comparação com o MapBioma.

5 CONCLUSÃO

Os resultados indicaram que a Máxima Entropia forneceu uma estimativa mais precisa da área efetiva e da área colhida de eucalipto na região, em comparação com o MapBiomas. A área mapeada pela Máxima Entropia foi mais próxima aos valores reportados pela Cenibra, sugerindo que esta técnica pode ser mais eficaz para mapear a silvicultura na região.

Esses resultados foram consistentes durante o período de 2019 a 2021, reforçando a eficácia do método de Máxima Entropia como uma ferramenta valiosa para a identificação e quantificação da silvicultura em uma área de interesse específico.

REFERÊNCIAS

- ANUAL, I. B. Á. R. Indústria Brasileira de Árvores. **São Paulo**, [s. l.], p. 100, 2022.
- ASNER, G. P.; KELLER, M.; PEREIRA, R.; ZWEEDE, J. C. Remote sensing of selective logging in Amazonia: Assessing limitations based on detailed field observations, Landsat ETM+, and textural analysis. **Remote Sensing of Environment**, [s. l.], v. 80, n. 3, p. 483–496, 2002.
- CHIANG, S. H.; VALDEZ, M. Tree species classification by integrating satellite imagery and topographic variables using maximum entropy method in a Mongolian forest. **Forests**, [s. l.], v. 10, n. 11, p. 961, 2019.
- CLARK, D. B.; KELLNER, J. R. Tropical forest biomass estimation and the fallacy of misplaced concreteness. **Journal of Vegetation Science**, [s. l.], v. 23, n. 6, p. 1191–1196, 2012.
- DELALAY, M.; TIWARI, V.; ZIEGLER, A. D.; GOPAL, V.; PASSY, P. Land-use and land-cover classification using Sentinel-2 data and machine-learning algorithms: operational method and its implementation for a mountainous area of Nepal. **Journal of Applied Remote Sensing**, [s. l.], v. 13, n. 01, p. 1, 2019.
- FITHIAN, W.; ELITH, J.; HASTIE, T.; KEITH, D. A. Bias correction in species distribution models: Pooling survey and collection data for multiple species. **Methods in Ecology and Evolution**, [s. l.], v. 6, n. 4, p. 424–438, 2015.
- GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, [s. l.], v. 202, n. 2016, p. 18–27, 2017. Disponível em: <http://dx.doi.org/10.1016/j.rse.2017.06.031>.
- LAURA, V. A. de; NETO, M. M. G.; ALMEIDA, R. G. De; ALVES, F. V. O eucalipto em sistemas de integração lavoura-pecuária-floresta (ILPF) no Bioma Pampa. **Embrapa**, [s. l.], p. 1110–1132, 2021.
- LIM, C. H.; KIM, Y. S.; WON, M.; KIM, S. J.; LEE, W. K. Can satellite-based data substitute for surveyed data to predict the spatial probability of forest fire? A geostatistical approach to forest fire in the Republic of Korea. **Geomatics, Natural Hazards and Risk**, [s. l.], v. 10, n. 1, p. 719–739, 2019.
- MACHADO, C. C.; SILVA, E. N. da; PEREIRA, R. S.; CASTRO, G. P. O setor florestal brasileiro e a colheita florestal. **Colheita Florestal**, [s. l.], p. 543, 2014.
- MARCIAL, M. C. N.; SANTILLAN, J. R. A maximum entropy approach for mapping falcata plantations in sentinel-2 imagery. *In: IEEE REGION 10 ANNUAL INTERNATIONAL CONFERENCE, PROCEEDINGS/TENCON, 2020*, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2020. p.

596–601.

MARTINS, F. B.; GONZAGA, G.; DOS SANTOS, D. F.; REBOITA, M. S. Classificação Climática De Köppen E De Thornthwaite Para Minas Gerais: Cenário Atual E Projeções Futuras. **Revista Brasileira de Climatologia**, [s. l.], v. 1, 2018.

MENDES, D.; CARLOS, D. ; MOREIRA DE OLIVEIRA¹, M.; DELGADO, R. C.; VITOR, ; VIDAL, M.; BORGES, I. B. Mapeamento de Áreas Agrícolas com Máquina de Vetor de Suporte no Noroeste de Minas Gerais, Brasil Mapping of Agricultural Areas with Support Vector Machine in the Northwest of Minas Gerais, Brazil. **Anuario do Instituto de Geociencias**, [s. l.], v. 43, n. 1, p. 33–41, 2020. Disponível em: http://dx.doi.org/10.11137/2020_1_33_41.

MITCHARD, E. T. A.; SAATCHI, S. S.; WHITE, L. J. T.; ABERNETHY, K. A.; JEFFERY, K. J.; LEWIS, S. L.; COLLINS, M.; LEFSKY, M. A.; LEAL, M. E.; WOODHOUSE, I. H.; MEIR, P. Mapping tropical forest biomass with radar and spaceborne LiDAR in Lopé National Park, Gabon: Overcoming problems of high biomass and persistent cloud. **Biogeosciences**, [s. l.], v. 9, n. 1, p. 179–191, 2012.

PEARSON, R. G.; RAXWORTHY, C. J.; NAKAMURA, M.; TOWNSEND PETERSON, A. Predicting species distributions from small numbers of occurrence records: A test case using cryptic geckos in Madagascar. **Journal of Biogeography**, [s. l.], v. 34, n. 1, p. 102–117, 2007.

PHIRI, D.; SIMWANDA, M.; SALEKIN, S.; NYIRENDA, V. R.; MURAYAMA, Y.; RANAGALAGE, M. Sentinel-2 data for land cover/use mapping: A review. **Remote Sensing**, [s. l.], v. 12, n. 14, p. 2291, 2020.

PRESTON, T. M.; JOHNSTON, A. N.; EBENHOCH, K. G.; DIEHL, R. H. Beyond presence mapping: predicting fractional cover of non-native vegetation in Sentinel-2 imagery using an ensemble of MaxEnt models. **Remote Sensing in Ecology and Conservation**, [s. l.], 2023.

RICHTER, R. Atmospheric correction of satellite data with haze removal including a haze/clear transition region. **Computers and Geosciences**, [s. l.], v. 22, n. 6, p. 675–681, 1996. Disponível em: <https://www.sciencedirect.com/science/article/pii/0098300496000106>. Acesso em: 2 abr. 2019.

SOUZA JUNIOR, C.; AZEVEDO, T. MapBiomias General Handbook. **MapBiomias: São Paulo, Brazil**, [s. l.], p. 1–23, 2017. Disponível em: http://mapbiomas-ecostage.s3.amazonaws.com/Base+de+dados/Metodologia/ATBD+MapBiomias+Geral+2017-03-22.pdf%0Ahttps://mapbiomas.storage.googleapis.com/base-de-dados/metodologia/colecao-2_3/ATBD-MapBiomias-Geral-2018-01-07.pdf.

SOUZA, C. M.; SHIMBO, J. Z.; ROSA, M. R.; PARENTE, L. L.; ALENCAR, A. A.; RUDORFF, B. F. T.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L. G.; SOUZA-

FILHO, P. W. M.; DE OLIVEIRA, S. W.; ROCHA, W. F.; FONSECA, A. V.; MARQUES, C. B.; DINIZ, C. G.; COSTA, D.; MONTEIRO, D.; ROSA, E. R.; VÉLEZ-MARTIN, E.; WEBER, E. J.; LENTI, F. E. B.; PATERNOST, F. F.; PAREYN, F. G. C.; SIQUEIRA, J. V.; VIERA, J. L.; NETO, L. C. F.; SARAIVA, M. M.; SALES, M. H.; SALGADO, M. P. G.; VASCONCELOS, R.; GALANO, S.; MESQUITA, V. V.; AZEVEDO, T. Reconstructing three decades of land use and land cover changes in brazilian biomes with landsat archive and earth engine. **Remote Sensing**, [s. l.], v. 12, n. 17, p. 2735, 2020.

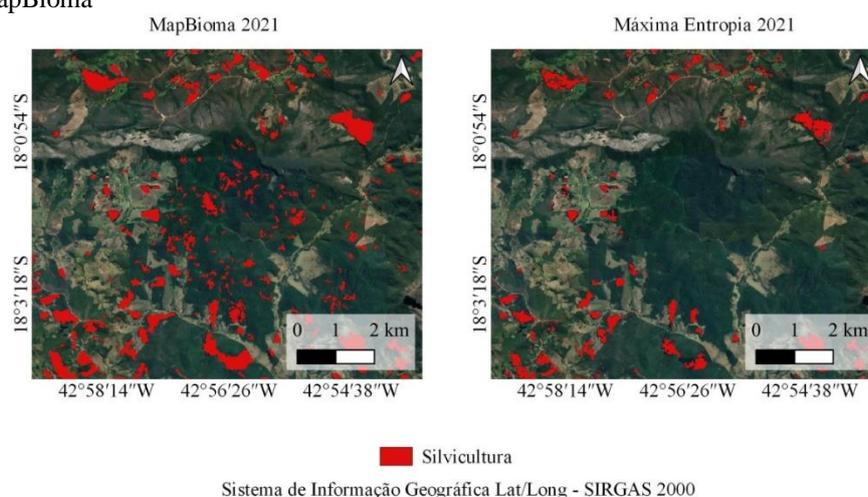
VAEZA, R. F.; OLIVEIRA, P. C. de; MAIA, A. G.; DISPERATI, A. A. Uso e ocupação do solo em bacia hidrográfica urbana a partir de imagens orbitais de alta resolução. **Floresta e Ambiente**, [s. l.], v. 17, n. 1, p. 23–29, 2010.

VENTER, Z. S.; SYDENHAM, M. A. K. Continental-scale land cover mapping at 10 m resolution over europe (Elc10). **Remote Sensing**, [s. l.], v. 13, n. 12, p. 2301, 2021.

VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, [s. l.], v. 185, p. 46–56, 2016. Disponível em: <http://dx.doi.org/10.1016/j.rse.2016.04.008>.

ANEXO A

Anexo A: Detalhe do efeito de salpicamento no mapeamento da área efetiva de silvicultura pelo método da Máxima entropia e o MapBioma



Fonte: Do autor (2023)