



INÁCIO SAMUEL CUNA

**MODELAGEM DA DISTRIBUIÇÃO ESPACIAL DO CAFÉ EM
MINAS GERAIS USANDO A TÉCNICA MAXENT**

LAVRAS – MG

2026

INÁCIO SAMUEL CUNA

**MODELAGEM DA DISTRIBUIÇÃO ESPACIAL DO CAFÉ EM MINAS GERAIS
USANDO A TÉCNICA MAXENT**

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

Prof. Dr. Marcelo de Carvalho Alves
Orientador

Prof. Dr. Fortunato Silva de Menezes;
Prof. Dr. Gladyston Rodrigues Carvalho
Coorientador

**LAVRAS – MG
2026**

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

Cuna, Inácio Samuel.

Modelagem da distribuição espacial do café em Minas Gerais usando a técnica
MaxEn / Inácio Samuel Cuna. - 2026.

119 p. : il.

Orientador: Marcelo de Carvalho Alves

Coorientador: Fortunato Silva de Meneses

Coorientador: Gladyston Rodrigues Carvalho

Dissertação (Mestrado Acadêmico) - Universidade Federal de Lavras, 2026.

Bibliografia.

1. mudanças climáticas. 2. clima tropical. 3. modelos de distribuição de espécies.
4. município de Nepomuceno. 5. município de Patrocínio. I. Alves, Marcelo de
Carvalho. II. Meneses, Fortunato Silva de. III. Carvalho, Gladyston Rodrigues. IV.
Universidade Federal de Lavras. V. Título.

INÁCIO SAMUEL CUNA

**MODELAGEM DA DISTRIBUIÇÃO ESPACIAL DO CAFÉ EM MINAS GERAIS
USANDO A TÉCNICA MAXENT**

**MODELING THE SPATIAL DISTRIBUTION OF COFFEE IN MINAS GERAIS
USING THE MAXENT APPROACH**

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

APROVADA em 23 de fevereiro de 2026.

Prof. Dr. Marcelo de Carvalho Alves UFLA

Prof. Dr. José Sérgio de Araujo IFSULDEMINAS

Prof. Dr. Bruno de Oliveira Schneider UFLA

Prof. Dr. Marcelo de Carvalho Alves
Orientador

Prof. Dr. Fortunato Silva de Menezes;
Prof. Dr. Gladyston Rodrigues Carvalho
Co-Orientador

**LAVRAS – MG
2026**

Dedico este trabalho aos meus pais, Samuel João Cuna e Auzenda Inácio Mate, e à minha irmã Elsa Samuel Cuna, que, com amor, dedicação e exemplo de vida, sempre me incentivaram a buscar o conhecimento e a acreditar no meu potencial. Desde cedo, ensinaram-me que a educação é a chave para abrir portas e que a coragem para trilhar novos caminhos é tão importante quanto a sabedoria adquirida. Agradeço a eles por cada palavra de incentivo, cada gesto de apoio e cada momento em que me lembraram de que o esforço e a persistência são fundamentais para superar desafios. É graças ao exemplo de vida que me deram, à força de suas convicções e à confiança inabalável em minhas capacidades que consegui enfrentar os obstáculos desta jornada acadêmica, sempre com a certeza de que não estou sozinho. Esta dedicatória é, portanto, um reconhecimento profundo e sincero do papel insubstituível que tiveram na construção do meu caminho, não apenas como estudante e pesquisador, mas como pessoa que acredita na importância de semear conhecimento, valores e sonhos que florescem ao longo da vida.

AGRADECIMENTOS

Agradeço, primeiramente, à minha família: minha esposa Luísa Sebastião Farranguane Cuna, minha irmã Sônia Samuel Cuna, e meus filhos Wendy da Elsa Inácio Cuna e Larson da Luísa Inácio Cuna, pelo carinho, compreensão, dedicação, acompanhamento e apoio incondicional ao longo de toda a minha trajetória acadêmica.

Expresso minha profunda gratidão ao meu orientador, Marcelo de Carvalho Alves, por sempre me guiar na busca pelo conhecimento e ajudar a transformar meus sonhos em realidade. Aos meus coorientadores, Gladyston Rodrigues Carvalho e Fortunato Silva de Menezes, agradeço pelos conselhos e pela orientação dedicada, fundamentais para o desenvolvimento deste trabalho.

Agradeço à Coordenação do Departamento de Engenharia Agrícola, pelo apoio na concretização dos aspectos acadêmicos e na minha permanência no Brasil, bem como aos professores da UFLA, pelos ensinamentos, dedicação e incentivo, que contribuíram de forma decisiva para o meu aprendizado e crescimento profissional.

Sou igualmente grato à CAPES pelo suporte financeiro concedido por meio da bolsa de estudos, que possibilitou a realização deste trabalho e o desenvolvimento das pesquisas aqui apresentadas.

A todos que, direta ou indiretamente, fizeram parte desta jornada, meu sincero agradecimento.

"A noção da própria ignorância é o primeiro passo para a busca do conhecimento."

(Autor Desconhecido)

RESUMO

O café é uma das principais commodities agrícolas tropicais, com elevada relevância econômica e social, destacando-se Minas Gerais como importante polo produtor. Contudo, a escassez de registros georreferenciados detalhados das áreas cultivadas dificulta o planejamento agrícola, o monitoramento da produção e a formulação de estratégias de adaptação às mudanças climáticas. Nesse contexto, o sensoriamento remoto combinado a modelos de distribuição de espécies representa uma abordagem promissora para mapear e monitorar lavouras de forma precisa. Este estudo avaliou o desempenho do modelo MaxEnt na modelagem espacial do cultivo de café em Minas Gerais, utilizando imagens de satélite Sentinel-2, Landsat-8 e MODIS, integradas a preditores espectrais, topográficos e bioclimáticos. Diferentes combinações de variáveis e proporções de treinamento e validação foram testadas, e o desempenho dos modelos foi avaliado por métricas como AUC, Kappa, acurácia, sensibilidade, especificidade e taxa de omissão. Os resultados indicaram que sensores de maior resolução espacial e espectral, como Sentinel-2 e Landsat, proporcionaram maior detalhamento em ecossistemas heterogêneos, assim como o uso de diferentes preditores permite melhor desempenho do modelo e redução da taxa de omissão. O MaxEnt apresentou desempenho de bom a excelente (AUC variando de 0,782 a 0,936), com baixas taxas de omissão, evidenciando robustez e boa capacidade preditiva.

Palavras-chave: mudanças climáticas; clima tropical; modelos de distribuição de espécies; município de Nepomuceno; município de Patrocínio.

ABSTRACT

Coffee is one of the main tropical agricultural commodities, with high economic and social relevance, with Minas Gerais standing out as an important production hub. However, the scarcity of detailed georeferenced records of cultivated areas hinders agricultural planning, production monitoring, and the development of strategies to adapt to climate change. In this context, remote sensing combined with species distribution models represents a promising approach to accurately map and monitor crops. This study evaluated the performance of the MaxEnt model in the spatial modeling of coffee cultivation in Minas Gerais, using satellite imagery from Sentinel-2, Landsat-8 and MODIS, integrated with spectral, topographic, and bioclimatic predictors. Different combinations of variables and training-to-validation ratios were tested, and model performance was assessed using metrics such as AUC, Kappa, accuracy, sensitivity, specificity, and omission rate. The results indicated that sensors with higher spatial and spectral resolution, such as Sentinel-2 and Landsat, provided greater detail in heterogeneous ecosystems, and the use of different predictive variables helps to improve the model and to reduce the omission rate. MaxEnt performance ranged from good to excellent (AUC ranging from 0.782 to 0.936), with low omission rates, demonstrating robustness and strong predictive capability.

Keywords: climate change; tropical climate; species distribution models; Nepomuceno municipality; Patrocínio municipality.

INDICADORES DE IMPACTO

O presente trabalho contribui para o avanço científico e tecnológico da cafeicultura brasileira ao desenvolver uma metodologia baseada em modelagem de distribuição espacial por Máxima Entropia (MaxEnt), integrada a dados de sensoriamento remoto e variáveis ambientais, para o mapeamento de áreas cultivadas com café no estado de Minas Gerais. Os resultados obtidos fornecem subsídios para o planejamento agrícola, monitoramento territorial e formulação de estratégias de adaptação às mudanças climáticas, permitindo identificar áreas com maior aptidão ao cultivo e compreender os fatores ambientais que condicionam a distribuição espacial da cafeicultura. Do ponto de vista econômico, a pesquisa contribui para o aprimoramento da gestão da cadeia produtiva do café, favorecendo a estimativa de áreas cultivadas, a alocação de recursos e o direcionamento de políticas públicas voltadas ao setor cafeeiro. Sob a perspectiva social, o estudo pode beneficiar produtores rurais, cooperativas, instituições de pesquisa e órgãos governamentais ao disponibilizar informações geoespaciais capazes de subsidiar a tomada de decisão e promover o desenvolvimento sustentável das regiões produtoras. Os impactos ambientais estão relacionados à utilização de ferramentas de monitoramento que permitem melhor compreensão da dinâmica de uso da terra e da influência das variáveis climáticas sobre a produção agrícola, contribuindo para estratégias de conservação e adaptação frente às mudanças ambientais. A pesquisa está alinhada principalmente aos Objetivos de Desenvolvimento Sustentável da Organização das Nações Unidas, em especial ao ODS 2 (Fome Zero e Agricultura Sustentável), ao ODS 12 (Consumo e Produção Responsáveis), ao ODS 13 (Ação Contra a Mudança do Clima) e ao ODS 15 (Vida Terrestre), além de se enquadrar nas áreas temáticas de Meio Ambiente, Tecnologia e Produção e Trabalho, conforme a Política Nacional de Extensão.

IMPACT INDICATORS

The present study contributes to the scientific and technological advancement of Brazilian coffee farming by developing a methodology based on Maximum Entropy (MaxEnt) spatial distribution modeling integrated with remote sensing data and environmental variables for mapping coffee-growing areas in the state of Minas Gerais, Brazil. The results provide support for agricultural planning, territorial monitoring, and the development of climate change adaptation strategies by identifying areas with higher suitability for coffee cultivation and improving the understanding of the environmental factors that influence the spatial distribution of coffee production. From an economic perspective, the research contributes to improving the management of the coffee production chain by supporting the estimation of cultivated areas, resource allocation, and the formulation of public policies aimed at the coffee sector. From a social perspective, the study may benefit farmers, cooperatives, research institutions, and governmental agencies by providing geospatial information that supports decision-making processes and promotes the sustainable development of coffee-producing regions. The environmental impacts are related to the use of monitoring tools that enable a better understanding of land-use dynamics and the influence of climatic variables on agricultural production, contributing to conservation strategies and adaptation measures in the face of environmental changes. This research is primarily aligned with the United Nations Sustainable Development Goals (SDGs), particularly SDG 2 (Zero Hunger and Sustainable Agriculture), SDG 12 (Responsible Consumption and Production), SDG 13 (Climate Action), and SDG 15 (Life on Land). Furthermore, it falls within the thematic areas of Environment, Technology and Production, and Work, as established by the Brazilian National Extension Policy.

LISTA DE FIGURAS

Figura 2.1 – Mapa da Produção Mundial de Café (2025).	25
Figura 3.1 – Principais fontes de dados de presença utilizadas na modelagem MaxEnt em cafeicultura.	46
Figura 3.2 – Preditores mais utilizados na modelagem do café com MaxEnt.	49
Figura 4.1 – Municípios de Nepomuceno e Patrocínio, Minas Gerais – Brasil.	60
Figura 4.2 – Correlogramas de Pearson para os preditores no município de Nepomuceno.	68
Figura 4.3 – Correlogramas de Pearson para os preditores no município de Patrocínio.	69
Figura 4.4 – Gráfico de AUC para os modelos compostos por preditores espectrais em Nepomuceno.	70
Figura 4.5 – Gráfico de AUC para os modelos compostos por preditores espectrais em Patrocínio.	71
Figura 4.6 – Gráfico de AUC para os modelos compostos por preditores topográficos em Nepomuceno.	73
Figura 4.7 – Gráfico de AUC para os modelos compostos por preditores topográficos em Patrocínio.	74
Figura 4.8 – Gráfico de AUC para os modelos compostos por preditores bioclimáticos em Nepomuceno.	75
Figura 4.9 – Gráfico de AUC para os modelos compostos por preditores bioclimáticos em Patrocínio.	76
Figura 4.10 – Gráfico de AUC para os modelos compostos por variáveis espectrais, bio- climáticas e topográficas em Nepomuceno.	77
Figura 4.11 – Gráfico do AUC para os modelos compostos por variáveis espectrais, bio- climáticas e topográficas em Patrocínio.	78
Figura 4.12 – Mapa de distribuição espacial do café no município de Nepomuceno em 2018, obtido a partir do modelo MaxEnt.	83
Figura 4.13 – Mapa de distribuição espacial do café no município de Patrocínio em 2018, obtido a partir do modelo MaxEnt.	84
Figura 5.1 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do Sentinel-2 em Nepomuceno.	88

Figura 5.2 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do Sentinel-2 em Patrocínio.	89
Figura 5.3 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do Landsat-8 em Nepomuceno.	90
Figura 5.4 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do Landsat-8 em Patrocínio.	91
Figura 5.5 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do sensor MODIS em Nepomuceno.	92
Figura 5.6 – Gráfico de AUC para os modelos compostos por variáveis bioclimáticas e bandas do sensor MODIS em Patrocínio.	93
Figura 5.7 – Mapa binário de distribuição de cultivos em Nepomuceno.	100
Figura 5.8 – Mapa contínuo de distribuição de cultivos em patrocínio	101
Figura 7.1 – Fluxograma PRISMA do processo de busca e seleção dos estudos incluídos na revisão.	116

LISTA DE TABELAS

Tabela 2.1 – Características do sensor Landsat-8/9 (OLI e TIRS)	28
Tabela 2.2 – Características do sensor Sentinel-2 (MSI)	29
Tabela 2.3 – Principais características espectrais e espaciais do sensor MODIS	30
Tabela 2.4 – Ambientes para execução do algoritmo MaxEnt	33
Tabela 3.1 – Variáveis bioclimáticas disponibilizadas pela base WorldClim.	50
Tabela 4.1 – Métricas de validação dos modelos aplicados ao município de Nepomuceno.	79
Tabela 4.2 – Métricas de validação dos modelos aplicados ao município de Patrocínio.	80
Tabela 5.1 – Métricas de validação dos modelos baseados em diferentes sensores orbitais para o município de Nepomuceno.	94
Tabela 5.2 – Métricas de validação dos modelos baseados em diferentes sensores orbitais para o município de Patrocínio.	96
Tabela 7.1 – Principais índices espectrais utilizados no mapeamento agrícola.	115
Tabela 7.2 – Exemplos de estudos com MaxEnt em cafeicultura.	117

LISTA DE ABREVIATURAS

aprox. Aproximadamente

ed. Edição

Fig. Figura

n. Número

p. Página

v. Volume / Versão

LISTA DE SIGLAS

AUC	Area Under the Curve (Área Sob a Curva)
AVI	Ashburn Vegetation Index
CABI	Centre for Agriculture and Bioscience International
CanESM5	Canadian Earth System Model version 5
CIAT	International Center for Tropical Agriculture
CMIP6	Coupled Model Intercomparison Project Phase 6
CNRM-CM6-1	Centre National de Recherches Météorologiques Climate Model
CTC	Capacidade de Troca Catiônica
FPR	False Positive Rate (Taxa de Falsos Positivos)
GBIF	Global Biodiversity Information Facility
GCM	Global Climate Model (Modelo de Circulação Global)
GEE	Google Earth Engine
GLI	Green Leaf Index
GPS	Global Positioning System
Landsat	Land Remote Sensing Satellite
MaxEnt	Maximum Entropy (Máxima Entropia)
MCARI	Modified Chlorophyll Absorption in Reflectance Index
MIROC6	Model for Interdisciplinary Research on Climate version 6
MODIS	Moderate Resolution Imaging Spectroradiometer
MRI-ESM2-0	Meteorological Research Institute Earth System Model
MSI	MultiSpectral Instrument (Sensor do Sentinel-2)

NDVI	Normalized Difference Vegetation Index
NIR	Near Infrared (Infravermelho Próximo)
ODS	Objetivos de Desenvolvimento Sustentável
OLI	Operational Land Imager (Sensor do Landsat-8)
pH	Potencial Hidrogeniônico
RCP	Representative Concentration Pathway
ROC	Receiver Operating Characteristic
SIG	Sistema de Informação Geográfica
SSP	Shared Socioeconomic Pathway
SRTM	Shuttle Radar Topography Mission
SWIR	Short-Wave Infrared (Infravermelho de Ondas Curtas)
TIRS	Thermal Infrared Sensor
TPR	True Positive Rate (Taxa de Verdadeiros Positivos)
TSS	True Skill Statistic
UFLA	Universidade Federal de Lavras
UKESM1-0-LL	United Kingdom Earth System Model
USGS	United States Geological Survey

LISTA DE SÍMBOLOS

$P(x)$	Probabilidade de ocorrência do pixel x .
Z	Constante de normalização.
λ_i	Coefficiente ajustado pelo modelo MaxEnt.
$\phi_i(x)$	Variável ambiental associada ao pixel x .
x_i	Coordenadas geográficas do ponto de ocorrência i .
lat_i	Latitude do ponto i .
lon_i	Longitude do ponto i .
r_{XY}	Coefficiente de correlação de Pearson.
$cov(X, Y)$	Covariância entre as variables X e Y .
σ_X	Desvio-padrão da variável X .
σ_Y	Desvio-padrão da variável Y .

SUMÁRIO

1	INTRODUÇÃO	20
1.1	Hipótese	23
1.2	Objetivos	23
1.2.1	Objetivo geral	23
1.2.2	Objetivos específicos	23
2	REFERENCIAL TEÓRICO	24
2.1	Cultura do café: origem, espécies, sistemas de cultivo e importância socioeconômica	24
2.2	Modelagem de distribuição de espécies: conceitos e aplicações em agricultura	25
2.3	Características dos principais sensores e satélites utilizados no mapeamento agrícola	26
2.3.1	Sensores Landsat	27
2.3.2	Sensores sentinel-2	27
2.3.3	Sensor MODIS	27
2.4	Principais índices espectrais utilizados no mapeamento de cultivos de café .	29
2.5	Modelagem com MaxEnt: conceitos e aplicações na agricultura	30
2.5.1	O software MaxEnt	32
	REFERÊNCIAS	33
	Referências Bibliográficas	34
3	ARTIGO 1 – MODELAGEM DO CULTIVO DE CAFÉ USANDO MAXENT: ABORDAGENS E DESAFIOS	44
3.1	Abordagem metodológica de busca de artigos de modelagem MaxEnt na cafeicultura	44
3.2	Etapas da modelagem MaxEnt no café	45
3.3	Obtenção de dados de ocorrência de café	45
3.4	Preparação de dados	46
3.5	Otimização do modelo	47
3.5.1	Variáveis bioclimáticas	48
3.5.2	Variáveis topográficas	51
3.5.3	Variáveis espectrais	53
3.5.4	Variáveis edáficas	53

3.5.5	Outras variáveis	54
3.6	Avaliação dos Modelos	55
3.7	Validação dos modelos	55
3.7.1	Matriz de confusão	55
3.7.2	Métricas de validação	56
3.8	Mapas de probabilidade de ocorrência de cultivos	57
4	ARTIGO 2 – INTEGRANDO VARIÁVEIS PREDITORAS MULTITEM- PORAIS PARA PREVER ÁREAS DE CULTIVO DE CAFÉ USANDO A TÉCNICA MAXENT	60
4.1	Área de estudo	60
4.2	Materiais e métodos	61
4.2.1	Fonte de dados	61
4.2.2	Seleção das variáveis preditoras	62
4.3	Modelagem MaxEnt	64
4.4	Métricas de desempenho	65
4.5	Mapas binários de presença de café	66
4.6	Resultados e discussão	66
4.6.1	Seleção de imagens sentinel-2	66
4.6.2	Seleção de preditores	67
4.6.3	Métricas de avaliação	70
4.6.4	Métricas de validação	79
4.6.5	Mapas binários de presença de café	81
5	ARTIGO 3 – INTEGRAÇÃO MULTISSENSOR E MULTITEMPORAL PARA MAPEAMENTO DE LAVOURAS DE CAFÉ USANDO A TÉCNICA MAXENT	85
5.1	Materiais e métodos	85
5.2	Resultados e discussão	86
5.2.1	Seleção de imagens	86
5.2.2	Métricas de avaliação	87
5.3	Métricas de validação	94
5.3.1	Mapas binários de presença de Café	99
6	CONCLUSÃO	102

	REFERÊNCIAS	104
	REFERÊNCIAS	104
7	APÊNDICE A	115
7.1	Índices espectrais utilizados na modelagem	115
7.2	Fluxograma PRISMA	115
7.3	Estudos revisados sobre MaxEnt na cafeicultura	115
7.4	Estudos revisados sobre MaxEnt na cafeicultura	115

1 INTRODUÇÃO

O café é uma das principais *commodities* agrícolas do mundo, desempenhando papel estratégico no comércio internacional, na geração de renda e no sustento de milhões de produtores em mais de 80 países (International Coffee Organization, 2023; Benti *et al.*, 2022). O Brasil destaca-se como o maior produtor e exportador mundial da cultura (U.S. Department of Agriculture, 2024a), sendo o estado de Minas Gerais responsável pela maior parcela da produção nacional (Abastecimento, 2023; Oliveira *et al.*, 2020). Nesse estado, regiões como o Cerrado Mineiro, Sul de Minas e Matas de Minas concentram importantes polos produtivos, caracterizados por distintas condições topográficas, climáticas, estruturais e socioeconômicas, fatores que influenciam diretamente a produtividade e a distribuição espacial da cafeicultura (Gomes *et al.*, 2020).

A distribuição do cafeeiro está intimamente associada às condições ambientais, especialmente relevo, clima, disponibilidade hídrica e propriedades do solo, tornando o conhecimento espacial dessas áreas fundamental para o planejamento agrícola e territorial. Informações detalhadas sobre a localização dos cultivos permitem aprimorar estimativas de produção, subsidiar o dimensionamento de insumos, orientar investimentos em infraestrutura agrícola e apoiar políticas públicas voltadas ao desenvolvimento regional. Além disso, a compreensão da distribuição espacial do café favorece análises sobre fatores que condicionam a produtividade, contribuindo para estratégias de manejo mais eficientes e sustentáveis (Ferrier, 2002).

Entretanto, apesar da relevância econômica e social da cultura, a disponibilidade de registros georreferenciados de áreas cultivadas ainda é limitada ou inconsistente em diversas regiões produtoras. Essa limitação compromete a precisão das análises espaciais aplicadas ao zoneamento agrícola, à avaliação da aptidão climática e à identificação de áreas vulneráveis a eventos extremos, dificultando a formulação de estratégias de adaptação e mitigação de riscos ambientais.

Nesse contexto, os Modelos de Distribuição de Espécies (MDE) surgem como ferramentas promissoras para representar espacialmente a ocorrência de cultivos agrícolas, estabelecendo relações estatísticas entre áreas de presença e variáveis ambientais. Esses modelos integram fatores como altitude, temperatura, precipitação e variáveis derivadas do sensoriamento remoto, permitindo estimar áreas ambientalmente favoráveis ao cultivo, analisar cenários climáticos e compreender padrões espaciais de distribuição agrícola (Peterson, 2003; Schneider; Alves; Fer-

reira, 2025; Júnior *et al.*, 2025). No caso da cafeicultura, os MDE apresentam elevado potencial para caracterizar áreas produtivas e identificar fatores ambientais determinantes da adequabilidade do cultivo.

Paralelamente, os avanços das geotecnologias e da computação em nuvem ampliaram significativamente a capacidade de processamento e integração de dados geoespaciais. Plataformas como o Google Earth Engine (GEE) possibilitam o acesso e o processamento de grandes volumes de dados provenientes de sensores orbitais, Sistemas de Informação Geográfica (SIG) e variáveis ambientais, favorecendo análises espaciais em larga escala com maior rapidez, reprodutibilidade e menor custo operacional (Tamiminia *et al.*, 2020; Hunt *et al.*, 2020). No setor agrícola, essas tecnologias têm contribuído para o desenvolvimento de produtos cartográficos voltados ao monitoramento, planejamento e suporte à tomada de decisão (Phiri *et al.*, 2020; Adrian; Sagan; Maimaitijiang, 2021).

Entre os algoritmos empregados em modelagem de distribuição espacial, o algoritmo de Máxima Entropia (MaxEnt) destaca-se pela robustez metodológica e pela eficiência no uso de dados de presença. Originalmente desenvolvido para modelagem de nicho ecológico, o MaxEnt vem sendo amplamente aplicado ao mapeamento de espécies cultivadas, especialmente em cenários marcados por elevada heterogeneidade ambiental e limitada disponibilidade de dados georreferenciados (Zhang *et al.*, 2022; Zhen-jiang; Guang-sheng, 2017). Fundamentado no princípio da máxima entropia, o algoritmo busca estimar a distribuição mais provável de ocorrência a partir das restrições impostas pelas variáveis ambientais, apresentando elevada capacidade preditiva mesmo em ambientes complexos, como áreas montanhosas e paisagens agrícolas heterogêneas (Bense; Beltrami, 2007).

Além disso, a crescente disponibilidade de dados provenientes de sensores orbitais, como Sentinel-2, Landsat e MODIS, tem ampliado as possibilidades de integração entre variáveis espectrais, topográficas e bioclimáticas na modelagem da distribuição agrícola. A combinação dessas múltiplas fontes de informação pode melhorar substancialmente a representação espacial dos cultivos, permitindo maior detalhamento das condições ambientais associadas à adequabilidade do cafeeiro.

Diante desse cenário, o presente trabalho tem como objetivo aplicar o algoritmo MaxEnt para modelar a distribuição espacial dos cultivos de café em Minas Gerais, utilizando variáveis ambientais derivadas de sensoriamento remoto, índices espectrais e dados bioclimáticos e topográficos. Busca-se avaliar o desempenho preditivo dos modelos na identificação de áreas

cultivadas, bem como compreender a contribuição relativa dos diferentes conjuntos de variáveis ambientais e sensores orbitais no mapeamento da cafeicultura. Espera-se, assim, contribuir para o avanço metodológico da modelagem espacial aplicada à agricultura e fornecer subsídios para estratégias territoriais mais eficientes e sustentáveis no setor cafeeiro.

1.1 Hipótese

O presente estudo fundamenta-se na seguinte hipótese:

- A modelagem por Máxima Entropia (MaxEnt) é eficaz para mapear a distribuição espacial de áreas cultivadas com café em Minas Gerais, e seu desempenho é significativamente aprimorado com a incorporação de dados espectrais multitemporais, variáveis ambientais e a integração de múltiplos sensores orbitais.

1.2 Objetivos

1.2.1 Objetivo geral

O objetivo principal desta pesquisa consiste em:

- Aplicar o algoritmo de Máxima Entropia (MaxEnt) para mapear a distribuição espacial dos cultivos de café no estado de Minas Gerais.

1.2.2 Objetivos específicos

Para o alcance do objetivo geral, definiram-se os seguintes objetivos específicos:

- Realizar uma revisão sistemática da literatura para identificar as principais abordagens e estratégias metodológicas utilizadas na aplicação do algoritmo MaxEnt ao cultivo de café;
- Identificar e selecionar as variáveis climáticas, topográficas e espectrais mais relevantes para a modelagem da distribuição espacial do cafeeiro em Minas Gerais;
- Investigar o efeito da integração multissensor e multitemporal no desempenho do modelo MaxEnt para o mapeamento de áreas cafeeiras.

2 REFERENCIAL TEÓRICO

2.1 Cultura do café: origem, espécies, sistemas de cultivo e importância socioeconômica

Originário das regiões tropicais do norte e centro da África, o café é atualmente cultivado em diversas partes do mundo (Zhang *et al.*, 2022; Chain-Guadarrama *et al.*, 2019). Estima-se que cerca de 25 milhões de pequenos agricultores estejam envolvidos em sua produção, sustentando direta ou indiretamente os meios de subsistência de mais de 100 milhões de pessoas (Aalto *et al.*, 2021).

Embora existam aproximadamente 124 espécies conhecidas do gênero *Coffea* (Davis *et al.*, 2019), apenas duas se destacam em escala comercial global: *Coffea arabica* L. (arábica) e *Coffea canephora* Pierre ex A. Froehner (robusta) (Jayakumar *et al.*, 2017).

O café arábica, originário das terras altas do sudoeste da Etiópia (Anthony *et al.*, 2002), representa cerca de 70% da produção mundial. É valorizado por sua qualidade superior e perfil sensorial refinado, sendo a principal escolha para cafés especiais (Aalto *et al.*, 2021). Seu cultivo exige condições agroclimáticas específicas, com temperaturas ideais entre 18 e 21°C e altitudes superiores a 600 metros. Temperaturas acima de 23°C, especialmente no período pós-floração, podem acelerar o amadurecimento dos frutos e comprometer a qualidade dos grãos (Camargo, 2010). Além disso, o arábica apresenta maior suscetibilidade a pragas e doenças, como a ferrugem do cafeeiro, o que eleva os custos de produção (Vossen; Bertrand; Charrier, 2015).


O café robusta, por sua vez, é nativo das florestas tropicais africanas e caracteriza-se por sua maior resistência a pragas, doenças e condições ambientais adversas. Pode ser cultivado em altitudes mais baixas, tolerando temperaturas entre 22 e 30°C. No entanto, variações intra-sazonais, sobretudo durante a floração, podem afetar negativamente a produtividade e a qualidade dos frutos (Kath *et al.*, 2021).

Quanto aos sistemas de cultivo, destacam-se o monocultivo, o consórcio com outras culturas e os sistemas agroflorestais. Estes últimos integram espécies lenhosas perenes, cultivos agrícolas e, por vezes, animais em uma mesma área produtiva. Tal configuração favorece a regulação microclimática, aumenta a umidade relativa do ar, melhora a ciclagem de nutrientes e promove a biodiversidade, especialmente de polinizadores (Nair; Kumar; Nair, 2021; Merle *et al.*, 2022; Moreira *et al.*, 2018; Jha; Vandermeer, 2010). Além dos benefícios ambientais,

os sistemas agroflorestais proporcionam vantagens socioeconômicas, como a diversificação da produção e a geração de renda complementar (Rice, 2011).

No ano de 2025, aproximadamente 170,68 milhões de sacas de café foram produzidas (considerando 60 kg por saca). O Brasil destacou-se como o maior produtor e exportador mundial, sendo responsável por mais de um terço da produção global, com um total de 65 milhões de sacas (U.S. Department of Agriculture, 2024b). Apresenta-se, na Fig. 2.1, o gráfico de distribuição da produção de café em 2025.

Figura 2.1 – Mapa da Produção Mundial de Café (2025).



Fonte: Elaborado pelo autor a partir de dados da USDA (2025).

2.2 Modelagem de distribuição de espécies: conceitos e aplicações em agricultura

Modelos de Distribuição de Espécies (MDE) são ferramentas computacionais que estimam a distribuição espacial potencial de organismos ou culturas agrícolas com base em registros georreferenciados de ocorrência e variáveis ambientais associadas a esses locais (Kou *et al.*, 2020). Embora tenham sido originalmente desenvolvidos no âmbito da ecologia e da bio-

geografia, os MDE vêm sendo amplamente aplicados em contextos agrícolas, especialmente na delimitação de zonas agroecológicas, no mapeamento de áreas aptas ao cultivo e na avaliação da vulnerabilidade climática de espécies cultivadas (Dimobe *et al.*, 2020; Guo *et al.*, 2019).

A principal premissa desses modelos é que a ocorrência de uma espécie está condicionada a fatores ambientais que definem seu nicho ecológico. A partir da correlação entre os pontos de presença e variáveis como temperatura, precipitação, altitude, tipo de solo e índices espectrais, torna-se possível inferir a distribuição espacial potencial da espécie em áreas ainda não amostradas, inclusive sob diferentes cenários de mudança climática ou de manejo agrícola.

Diversos algoritmos têm sido empregados na modelagem da distribuição de espécies. Entre os mais utilizados, destacam-se: o modelo de Máxima Entropia (MaxEnt), os algoritmos genéticos para predição de conjuntos de regras (GARP), as simulações sob mudanças climáticas (CLIMEX), a análise de fatores de nicho ecológico (ENFA), o sistema de predição bioclimática (BIOCLIM), além de abordagens estatísticas como modelos lineares generalizados (GLM) e modelos aditivos generalizados (GAM) (Abdelaal *et al.*, 2020; Rong *et al.*, 2019; Zhang; Zhang; Tao, 2019).

Mais do que ferramentas de predição espacial, os MDE oferecem suporte à tomada de decisão em múltiplas frentes. Podem ser utilizados para identificar áreas com risco fitossanitário, orientar estratégias de adaptação climática, otimizar a alocação de recursos na agricultura de precisão, apoiar o ordenamento do uso da terra e embasar políticas públicas com base em evidências ambientais e geoespaciais (Elith; Leathwick, 2009).

2.3 Características dos principais sensores e satélites utilizados no mapeamento agrícola

O sensoriamento remoto é uma técnica que permite a aquisição de informações sobre a superfície terrestre à distância, sem contato físico direto com o objeto ou a área de interesse (Chemura; Mutanga; Dube, 2018). Essa tecnologia tem se consolidado como uma ferramenta econômica, ágil e eficaz, sendo amplamente utilizada no monitoramento e no mapeamento da vegetação (Leboeuf, 2000).

Por meio de sensores capazes de captar radiações refletidas ou emitidas pelos alvos na superfície da Terra — como luz visível, radiação infravermelha e micro-ondas — o sensoriamento remoto possibilita a obtenção de dados em grandes áreas com elevada frequência temporal (Chuvienco, 2020). Esses dados são processados para gerar informações sobre atribu-

tos como composição, temperatura e umidade das superfícies. As plataformas de coleta variam desde satélites e radares até veículos aéreos não tripulados (VANTs), como drones (Tsouros; Bibi; Sarigiannidis, 2019).

Entre as fontes de dados mais utilizadas no monitoramento da vegetação destacam-se os sensores das missões Landsat, Sentinel (Alves *et al.*, 2023) e MODIS.

2.3.1 Sensores Landsat

Os dados Landsat, disponibilizados gratuitamente pelo *United States Geological Survey* (USGS), destacam-se pelo longo histórico de observações contínuas e pela especificidade dos sensores voltados ao monitoramento de recursos naturais (Alves *et al.*, 2023). A Tabela 2.1 apresenta as principais características espectrais e espaciais do sensor Landsat-8/9 (OLI e TIRS), amplamente utilizado no mapeamento da cultura do café (Alves *et al.*, 2023).

2.3.2 Sensores sentinel-2

O Sentinel-2, lançado em 2015, tem se mostrado uma alternativa eficaz para o monitoramento de áreas agrícolas, inclusive em regiões com alta cobertura de nuvens (Claverie; outros, 2018). A Tabela 2.2 apresenta as principais características espectrais e espaciais do sensor Sentinel-2 (MSI), amplamente utilizado no mapeamento da cultura do café (Alves *et al.*, 2023).

2.3.3 Sensor MODIS

O MODIS *Moderate Resolution Imaging Spectroradiometer* é um dos cinco instrumentos a bordo do satélite Terra, integrante da missão EOS-AM. Os outros sensores embarcados são: CERES, ASTER, MISR e MOPITT. O MODIS foi projetado para atender às demandas de três grandes áreas de estudo: atmosfera, oceanos e superfície terrestre, com bandas espectrais e resoluções espaciais selecionadas para esses objetivos, além de cobertura global quase diária (1–2 dias) (Justice *et al.*, 2002).

Suas 36 bandas espectrais, distribuídas ao longo do espectro eletromagnético, permitem observar propriedades das nuvens, a dinâmica e as características da vegetação terrestre, bem como a temperatura da superfície dos oceanos (Salomonson; Toll, 1990; Xiong; Barnes, 2006).

Tabela 2.1 – Características do sensor Landsat-8/9 (OLI e TIRS)

Banda	Nome da Banda	Res. Espectral (μm)	Res. Espacial (m)
1	Aerossol costeiro (Coastal/Aerosol)	0,435–0,451	30
2	Azul (B)	0,452–0,512	30
3	Verde (G)	0,533–0,590	30
4	Vermelho (R)	0,636–0,673	30
5	Infravermelho próximo (NIR)	0,851–0,879	30
6	Infravermelho de ondas curtas 1 (SWIR1)	1,566–1,651	30
7	Infravermelho de ondas curtas 2 (SWIR2)	2,107–2,294	30
8	Pancromática (PAN)	0,503–0,676	15
9	Cirrus	1,363–1,384	30
10	Infravermelho térmico 1 (TIRS1)	10,600–11,190	100
11	Infravermelho térmico 2 (TIRS2)	11,500–12,510	100

Fonte: Elaborado pelo autor com base em USGS (2025).

Essas bandas foram planejadas para evitar regiões de forte absorção atmosférica, além de outras feições espectrais específicas, como as linhas de Fraunhofer (Salomonson *et al.*, 1987; Strahler *et al.*, 1999).

A Tabela 2.3 apresenta um resumo das principais faixas espectrais e resoluções espaciais do sensor MODIS, com destaque para as bandas mais utilizadas em estudos ambientais e agrícolas.

Esses sensores apresentam diferentes modos de aquisição e combinam altas resoluções espacial, temporal e espectral, o que amplia o escopo de aplicações e enriquece as análises (Alves *et al.*, 2023).

Tabela 2.2 – Características do sensor Sentinel-2 (MSI)

Banda	Nome da Banda	Res. Espectral (µm)	Res. Espacial (m)
1	Aerossol costeiro	0,443	60
2	Azul (B)	0,493	10
3	Verde (G)	0,560	10
4	Vermelho (R)	0,665	10
5	Borda vermelha 1 (RE1)	0,704	20
6	Borda vermelha 2 (RE2)	0,740	20
7	Borda vermelha 3 (RE3)	0,783	20
8a	Infravermelho próximo estreito (NIRn)	0,865	20
8	Infravermelho próximo (NIR)	0,833	10
9	Vapor d'água	0,945	60
10	Cirrus	1,374	60
11	Infravermelho de ondas curtas 1 (SWIR1)	1,6137	20
12	Infravermelho de ondas curtas 2 (SWIR2)	2,2024	20

Fonte: Elaborado pelo autor com base em ESA (2025)

2.4 Principais índices espectrais utilizados no mapeamento de cultivos de café

Os índices espectrais são métricas derivadas das combinações de bandas multiespectrais, amplamente utilizadas na agricultura para avaliar a condição da vegetação de forma rápida e quantitativa. Eles fornecem informações essenciais sobre a saúde das plantas, produtividade, teor de clorofila e presença de estresses hídricos ou nutricionais, entre outros atributos biofísicos (Soares *et al.*, 2022).

Estudos recentes identificaram mais de 45 índices com potencial aplicação em diferentes fases do ciclo do café — desde o plantio até a maturação dos frutos, incluindo o monitoramento

Tabela 2.3 – Principais características espectrais e espaciais do sensor MODIS

Bandas	Principais aplicações	Faixa espectral (µm)	Res. espacial (m)
1–2	Vegetação, NDVI, dinâmica da cobertura terrestre	0,620–0,876	250
3–7	Propriedades da vegetação, solo e queimadas	0,459–2,155	500
8–16	Aerossóis, vapor d’água, propriedades de nuvens	0,405–0,877	1.000
17–19	Vapor d’água atmosférico	0,890–0,965	1.000
20–23	Temperatura da superfície terrestre e nuvens	3,660–4,080	1.000
24–25	Temperatura da superfície e propriedades de nuvens	4,433–4,498	1.000
26	Detecção de cirrus	1,360–1,390	1.000
27–30	Vapor d’água e temperatura atmosférica	6,535–8,700	1.000
31–32	Temperatura da superfície terrestre e oceânica	10,780–12,270	1.000
33–36	Propriedades de nuvens e balanço radiativo	13,185–14,385	1.000

Fonte: Elaborado pelo autor com base em NASA (2025).

de pragas e doenças — demonstrando a versatilidade do sensoriamento remoto no apoio à cafeicultura (Soares *et al.*, 2022).

Os principais índices espectrais utilizados no mapeamento agrícola estão descritos na Tabela 7.1.

2.5 Modelagem com MaxEnt: conceitos e aplicações na agricultura

O algoritmo MaxEnt (Máxima Entropia) é uma técnica de aprendizado de máquina amplamente empregada em estudos de ecologia, adequação ambiental e, mais recentemente, em aplicações agrícolas e de sensoriamento remoto (Buckley; al., 2010; Elith *et al.*, 2011). Fundamenta-se no princípio da entropia máxima, segundo o qual, entre todas as distribuições possíveis, deve-se preferir aquela com o maior grau de incerteza (ou menor viés), desde que res-

peite as restrições impostas pelos dados observados (Phillips; Dudík, 2004; Phillips; Anderson; Schapire, 2006).

Segundo a teoria da informação de Shannon (Shannon, 1948), a entropia representa a quantidade de incerteza de um sistema. Ao maximizar esse valor, o algoritmo busca a distribuição mais uniforme possível, compatível com os dados disponíveis, evitando suposições indevidas (Jaynes, 1990; Allahverdyan, 2021). Essa característica torna o MaxEnt particularmente adequado para cenários com dados restritos a registros de presença — condição comum em estudos com espécies nativas, pragas agrícolas ou culturas permanentes em larga escala.

Matematicamente, o modelo pode ser representado pela distribuição exponencial:

$$P(x) = \frac{1}{Z} \exp \left(\sum_i \lambda_i \phi_i(x) \right),$$

em que $P(x)$ é a probabilidade de ocorrência do pixel x , λ_i são os coeficientes ajustados pelo modelo, $\phi_i(x)$ representa as variáveis ambientais associadas a x , e Z é a constante de normalização:

$$Z = \int_X \exp \left(\sum_i \lambda_i \phi_i(x) \right) dx.$$

De acordo com (Phillips; Anderson; Schapire, 2006), a aplicação do MaxEnt baseia-se em três pressupostos principais:

- O espaço geográfico é discretizado em pixels com probabilidades associadas;
- Os pontos de presença representam amostras da ocorrência real da espécie ou cultura;
- As variáveis ambientais atuam como restrições que informam a construção da distribuição estimada.

O uso do MaxEnt está amplamente documentado em diferentes contextos, incluindo:

- Estimativa da distribuição potencial de espécies nativas e invasoras (Xu *et al.*, 2020; Wei *et al.*, 2021);
- Identificação de variáveis-chave para a sobrevivência de espécies (Souza *et al.*, 2019; Kamyó; Asanok, 2020);

- Projeção de cenários frente às mudanças climáticas (Yang *et al.*, 2022; Singh; Saran; Kocaman, 2021; Boral; Moktan, 2021; Thapa *et al.*, 2021; Fitzgibbon; Pisut; Fleisher, 2022);
- Modelagem da expansão de pragas e doenças agrícolas (Mushtaq *et al.*, 2021);
- Delimitação de zonas com aptidão ambiental para cultivos agrícolas, especialmente em regiões montanhosas ou de acesso limitado.

2.5.1 O software MaxEnt

O MaxEnt é um software multiplataforma, desenvolvido em Java, voltado à modelagem da distribuição potencial de espécies com base em dados de presença e variáveis ambientais contínuas ou categóricas (Phillips; Anderson; Schapire, 2006; Phillips; Dudík; Schapire, 2008). Sua ampla adoção se deve à interface intuitiva, à facilidade de integração com dados de SIG e à robustez do algoritmo estatístico (Li, 2024).

A modelagem segue uma abordagem presença-fundo, que compara os registros georreferenciados de presença com amostras aleatórias extraídas do espaço geográfico de estudo. A partir dessas relações, o modelo estima a probabilidade de ocorrência da espécie ou cultura, delineando seu nicho ecológico e produzindo mapas contínuos de aptidão ambiental.

A interface gráfica da versão standalone (arquivo ‘.jar’) permite a importação de arquivos de ocorrência em ‘.csv’ e camadas ambientais no formato raster ‘.asc’. O usuário pode configurar parâmetros como número de iterações, regularização, replicações cruzadas e métricas de avaliação. Como saída, o software gera: Mapas de probabilidade de ocorrência (raster), Curvas de resposta para cada variável, Tabelas com métricas de desempenho (AUC, ganho de entropia, contribuição das variáveis) e Relatórios em ‘.html’ com gráficos interativos e sumários estatísticos.

Além da versão independente, o MaxEnt está disponível em diversos ambientes computacionais, conforme apresentado na Tabela 2.4.

A disponibilidade em diferentes plataformas amplia as possibilidades de aplicação, permitindo análises exploratórias com dados mínimos ou modelagens avançadas com replicações, calibração e validação estatística. Na agricultura, o MaxEnt se consolida como ferramenta es-

Tabela 2.4 – Ambientes para execução do algoritmo MaxEnt

Ambiente	Pacotes / Recursos	Fonte:
MaxEnt Standalone	Aplicativo Java (.jar) com interface gráfica	
R	Pacotes dismo, maxnet, ENMeval	
Python	Pacote pyMaxEnt	
Google Earth Engine (GEE)	Execução em nuvem via JavaScript	
QGIS	Plugin para modelagem de nicho ecológico	
ArcGIS	Ferramentas via ModelBuilder ou scripts Python	

Elaborado pelo autor (2026).

tratégica para o mapeamento de cultivos, sobretudo em contextos onde há escassez de dados de ausência, como ocorre na cafeicultura mineira.

REFERÊNCIAS BIBLIOGRÁFICAS

AALTO, I. J. *et al.* Strong influence of trees outside forest in regulating microclimate of intensively modified afro-montane landscapes. **Biogeosciences Discussions**, Göttingen, Germany, v. 2021, p. 1–34, 2021.

ABASTECIMENTO, C. N. de. **Acompanhamento da Safra Brasileira: Café — 2º Levantamento, Maio 2023**. 2023. <https://www.conab.gov.br/info-agro/safras/cafe>. Acesso em: 31 maio 2025.

ABDELAAL, M. *et al.* Predicting the potential current and future distribution of the endangered endemic vascular plant *Primula boveana* Decne. ex Duby in Egypt. **Plants**, MDPI, v. 9, n. 8, p. 957, 2020.

ABIGABA, D. *et al.* The potential of agroforestry to buffer climate change impacts on suitability of coffee and banana in Uganda. **Agroforestry Systems**, Springer, v. 98, n. 6, p. 1555–1577, 2024.

ADANE, A. Analysis of current and future bioclimatic suitability for *C. arabica* production in Ethiopia. **Plos one**, Public Library of Science San Francisco, CA USA, v. 19, n. 10, p. e0310945, 2024.

ADRIAN, J.; SAGAN, V.; MAIMAITIJIANG, M. Sentinel SAR-optical fusion for crop type mapping using deep learning and Google Earth Engine. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 175, p. 215–235, 2021.

ALLAHVERDIYAN, A. E. Validity of the maximum entropy principle in inference, and the origins of uncertainty. **Entropy**, MDPI, v. 23, n. 4, p. 484, 2021.

ALLOUCHE, O.; TSOAR, A.; KADMON, R. Assessing the accuracy of species distribution models: prevalence, kappa and the true skill statistic (tss). **Journal of applied ecology**, Wiley Online Library, v. 43, n. 6, p. 1223–1232, 2006.

ALVES, E. L.; PEREIRA, F. A. C.; DALCHIAVON, F. C. Potencial econômico da utilização de micro-terraceamento em lavouras de café: um estudo de caso. **Revista iPecege**, v. 3, n. 1, p. 24–38, 2017.

ALVES, M. de C. *et al.* Multisensor analysis for environmental targets identification in the region of Funil Dam, State of Minas Gerais, Brazil. **Applied Geomatics**, Springer, v. 15, n. 4, p. 807–827, 2023.

AMARO, G. *et al.* Efeito da extensão da área de estudo sobre a distribuição potencial de espécies: Um estudo com modelos MaxEnt para *Raoiella indica* Hirst (acarí: Tenuipalpidae) no Brasil. [s.d.].

ANTHONY, F. *et al.* The origin of cultivated *Coffea arabica* L. varieties revealed by AFLP and SSR markers. **Theoretical and Applied Genetics**, Springer, v. 104, p. 894–900, 2002.

ARAÚJO, M. B.; GUISAN, A. Five (or so) challenges for species distribution modelling. **Journal of biogeography**, Wiley Online Library, v. 33, n. 10, p. 1677–1688, 2006.

- ARIA, M.; CUCCURULLO, C. bibliometrix: An r-tool for comprehensive science mapping analysis. **Journal of Informetrics**, v. 11, n. 4, p. 959–975, 2017. ISSN 1751-1577. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1751157717300500>.
- ASNER, G. P. Cloud cover in landsat observations of the brazilian amazon. **International journal of remote sensing**, Taylor & Francis, v. 22, n. 18, p. 3855–3862, 2001.
- BARROS, M. A.; MOREIRA, M. A.; RUDORFF, B. F. T. Dados interferométricos para modelagem topográfica e caracterização ambiental do café em escala municipal. **Sociedade & Natureza**, SciELO Brasil, v. 19, p. 33–50, 2007.
- BENSE, V.; BELTRAMI, H. Impact of horizontal groundwater flow and localized deforestation on the development of shallow temperature anomalies. **Journal of Geophysical Research: Earth Surface**, Wiley Online Library, v. 112, n. F4, 2007.
- BENTI, F. *et al.* Modeling coffee (*coffea arabica* l.) climate suitability under current and future scenario in jimma zone, ethiopia. **Environmental Monitoring and Assessment**, Springer, v. 194, n. 4, p. 271, 2022.
- BEVEN, K. J.; KIRKBY, M. J. A physically based, variable contributing area model of basin hydrology / un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. **Hydrological Sciences Journal**, Taylor & Francis, v. 24, n. 1, p. 43–69, 1979.
- BORAL, D.; MOKTAN, S. Predictive distribution modeling of *swertia bimaculata* in darjeeling-sikkim eastern himalaya using maxent: current and future scenarios. **Ecological Processes**, Springer, v. 10, n. 1, p. 26, 2021.
- BUCKLEY, L. B.; AL. *et.* Can niche-based distribution models outperform spatial interpolation? **Global Ecology and Biogeography**, Wiley, v. 19, n. 6, p. 613–620, 2010.
- BUNN, C. e. a. A bitter cup: climate change profile of global production of arabica and robusta coffee. **Climatic Change**, v. 129, n. 1, p. 89–101, 2015.
- BUNN, C. e. a. A bitter cup: climate change profile of global production of arabica and robusta coffee. **Climatic Change**, v. 129, n. 1, p. 89–101, 2015.
- CAMARGO, M. B. P. d. The impact of climatic variability and climate change on arabic coffee crop in brazil. **Bragantia**, SciELO Brasil, v. 69, p. 239–247, 2010.
- CANTON, H. Food and agriculture organization of the united nations—fao. In: **The Europa directory of international organizations 2021**. [S.l.]: Routledge, 2021. p. 297–305.
- CHAIN-GUADARRAMA, A. *et al.* Ecosystem services by birds and bees to coffee in a changing climate: A review of coffee berry borer control and pollination. **Agriculture, Ecosystems & Environment**, Elsevier, v. 280, p. 53–67, 2019.
- CHALCHISSA, F. B.; DIGA, G. M.; TOLOSSA, A. R. Modeling the responses of coffee (*coffea arabica* l.) distribution to current and future climate change in jimma zone, ethiopia. **SAINS TANAH-Journal of Soil Science and Agroclimatology**, v. 19, n. 1, p. 19–32, 2022.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. Mapping spatial variability of foliar nitrogen in coffee (*coffea arabica* l.) plantations with multispectral sentinel-2 msi data. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 138, p. 1–11, 2018.

CHUVIECO, E. **Fundamentals of Satellite Remote Sensing: An Environmental Approach**. 3rd. ed. [S.l.]: CRC Press, 2020.

CLAVERIE, M.; OUTROS. Superando limitações de cobertura de nuvens no sentinel-2 para mapeamento terrestre. **Remote Sensing of Environment**, v. 204, p. 15–27, 2018.

COHEN, I. *et al.* Pearson correlation coefficient. **Noise reduction in speech processing**, Springer, p. 1–4, 2009.

DAVIS, A. P. *et al.* High extinction risk for wild coffee species and implications for coffee sector sustainability. **Science advances**, American Association for the Advancement of Science, v. 5, n. 1, p. eaav3473, 2019.

DAVIS, A. P. *et al.* The impact of climate change on indigenous arabica coffee (*coffea arabica*): predicting future trends and identifying priorities. **PloS one**, Public Library of Science San Francisco, USA, v. 7, n. 11, p. e47981, 2012.

DIMOBE, K. *et al.* Climate change reduces the distribution area of the shea tree (*vitellaria paradoxa* cf *gaertn.*) in burkina faso. **Journal of Arid Environments**, Elsevier, v. 181, p. 104237, 2020.

DORMANN, C. F. *et al.* Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. **Ecography**, Wiley Online Library, v. 36, n. 1, p. 27–46, 2013.

DRUSCH, M. *et al.* Sentinel-2: Esa's optical high-resolution mission for gmes operational services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012.

ELITH, J.; LEATHWICK, J. R. Species distribution models: ecological explanation and prediction across space and time. **Annual review of ecology, evolution, and systematics**, Annual Reviews, v. 40, n. 1, p. 677–697, 2009.

ELITH, J. *et al.* A statistical explanation of maxent for ecologists. **Diversity and distributions**, Wiley Online Library, v. 17, n. 1, p. 43–57, 2011.

FAIN, S. J. *et al.* Climate change and coffee: Assessing vulnerability by modeling future climate suitability in the caribbean island of puerto rico. **Climatic Change**, Springer, v. 146, n. 1–2, p. 175–186, 2018.

FENG, X. *et al.* Collinearity in ecological niche modeling: Confusions and challenges. **Ecology and evolution**, Wiley Online Library, v. 9, n. 18, p. 10365–10376, 2019.

FERRIER, S. Mapping spatial pattern in biodiversity for regional conservation planning: where to from here? **Systematic biology**, Society of Systematic Zoology, v. 51, n. 2, p. 331–363, 2002.

FICK, S. E.; HIJMANS, R. J. Worldclim 2: new 1-km spatial resolution climate surfaces for global land areas. **International Journal of Climatology**, John Wiley & Sons, v. 37, n. 12, p. 4302–4315, 2017.

FIELDING, A.; BELL, J. A review of methods for the assessment of prediction errors in conservation presence/absence models. **Environmental Conservation**, v. 24, n. 1, p. 38–49, 2007.

- FIELDING, A. H.; BELL, J. F. A review of methods for the assessment of prediction errors in conservation presence/absence models. **Environmental conservation**, Cambridge University Press, v. 24, n. 1, p. 38–49, 1997.
- FITZGIBBON, A.; PISUT, D.; FLEISHER, D. Evaluation of maximum entropy (maxent) machine learning model to assess relationships between climate and corn suitability. **Land**, MDPI, v. 11, n. 9, p. 1382, 2022.
- FOODY, G. M. Valuing map validation: The need for rigorous land cover map accuracy assessment. **Landscape and Urban Planning**, v. 143, p. 1–6, 2015.
- Garnier *et al.* **viridis(Lite) - Colorblind-Friendly Color Maps for R**. [S.l.], 2024. Viridis package version 0.6.5. Disponível em: <https://sjmgarnier.github.io/viridis/>.
- GERONIMO-ISIDRO, F. *et al.* Spatiotemporal modeling of hemileia vastatrix using multiple machine learning algorithms: implications for disease surveillance of the coffee leaf rust disease in the philippines. **Journal of Plant Pathology**, Springer, p. 1–16, 2025.
- GIRALDO-SANCLEMENTE, W. *et al.* Coffee yield is influenced by soil properties, not by nitrogen fertilization strategies, under greenhouse gas monitoring in a costa rican andisol. **Frontiers in Agronomy**, Frontiers Media SA, v. 7, p. 1729122, 2025.
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from eos-modis. **Remote sensing of Environment**, Elsevier, v. 58, n. 3, p. 289–298, 1996.
- GOMES, L. C. *et al.* Agroforestry systems can mitigate the impacts of climate change on coffee production: a spatially explicit assessment in brazil. **Agriculture, Ecosystems & Environment**, Elsevier, v. 294, p. 106858, 2020.
- GORELICK, N. *et al.* Google earth engine: Planetary-scale geospatial analysis for everyone. **Remote sensing of Environment**, Elsevier, v. 202, p. 18–27, 2017.
- GUO, Y. *et al.* Predicting the impacts of climate change, soils and vegetation types on the geographic distribution of polyporus umbellatus in china. **Science of the Total Environment**, Elsevier, v. 648, p. 1–11, 2019.
- HAILU, B. T. *et al.* Assessing spatial distribution of coffea arabica l. in ethiopia's highlands using species distribution models and geospatial analysis methods. **Ecological Informatics**, Elsevier, v. 42, p. 79–89, 2017.
- HENGL, T. *et al.* Soilgrids250m: Global gridded soil information based on machine learning. **PLoS one**, Public Library of Science San Francisco, CA USA, v. 12, n. 2, p. e0169748, 2017.
- HIJMANS, R. J.; BROWN, A.; BARBOSA, M. **terra: Spatial Data Analysis**. [S.l.], 2026. R package version 1.9-1. Disponível em: <https://CRAN.R-project.org/package=terra>.
- HIJMANS, R. J. *et al.* Very high resolution interpolated climate surfaces for global land areas. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, Wiley Online Library, v. 25, n. 15, p. 1965–1978, 2005.
- HIJMANS, R. J.; ELITH, J. Species distribution models. **Spatial Data Science (rspatial. org)**. Available online at <https://rspatial.org/sdm> [Google Scholar], 2021.

HONG, D. *et al.* More diverse means better: Multimodal deep learning meets remote-sensing imagery classification. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 59, n. 5, p. 4340–4354, 2020.

HUETE, A. R. *et al.* Overview of the radiometric and biophysical performance of the modis vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195–213, 2002.

HUNT, D. A. *et al.* Review of remote sensing methods to map coffee production systems. **Remote Sensing**, MDPI, v. 12, n. 12, p. 2041, 2020.

Instituto Brasileiro de Geografia e Estatística (IBGE). **Cidades e Estados**. 2022. <https://www.ibge.gov.br/cidades-e-estados.html>. Acesso em: 15 jun. 2025.

International Coffee Organization. **The Economics of Coffee**. 2023. <https://ico.org>. Acesso em: 31 maio 2025.

JAYAKUMAR, M. *et al.* Impact of climate variability on coffee yield in india—with a micro-level case study using long-term coffee yield data of humid tropical kerala. **Climatic Change**, Springer, v. 145, p. 335–349, 2017.

JAYNES, E. T. **Probability Theory: The Logic of Science**. [S.l.]: Cambridge University Press, 1990. Published posthumously.

JHA, S.; VANDERMEER, J. Impacts of coffee agroforestry management on tropical bee communities. **Biological Conservation**, Elsevier, v. 143, n. 6, p. 1423–1431, 2010.

JIMÉNEZ, A. A. *et al.* Potential coffee distribution in a central-western region of mexico. **Ecologies**, MDPI, v. 4, n. 2, p. 269–287, 2023.

JIMÉNEZ-VALVERDE, A. e. a. Limitations of niche-based models in ecological applications: a review. **Diversity and Distributions**, v. 14, n. 3, p. 167–176, 2008.

JÚNIOR, F. V. de C. *et al.* Agroclimatic and mechanization zoning of sugarcane associated with ethanol production potential in minas gerais under climate change scenarios. **Journal of Geovisualization and Spatial Analysis**, Springer, v. 9, n. 1, p. 25, 2025.

JUSTICE, C. *et al.* The modis fire products. **Remote sensing of Environment**, Elsevier, v. 83, n. 1-2, p. 244–262, 2002.

KAMYO, T.; ASANOK, L. Modeling habitat suitability of dipterocarpus alatus (dipterocarpaceae) using maxent along the chao phraya river in central thailand. **Forest Science and Technology**, Taylor & Francis, v. 16, n. 1, p. 1–7, 2020.

KASSAMBARA, A.; KASSAMBARA, M. A. Package ‘ggcorrplot’. **R package version 0.1**, v. 3, n. 3, p. 908, 2019.

KATH, J. *et al.* Temperature and rainfall impacts on robusta coffee bean characteristics. **Climate Risk Management**, Elsevier, v. 32, p. 100281, 2021.

KOU, J. *et al.* The moss genus didymodon as an indicator of climate change on the tibetan plateau. **Ecological Indicators**, Elsevier, v. 113, p. 106204, 2020.

- LÄDERACH, P. *et al.* Climate change adaptation of coffee production in space and time. **Climatic change**, Springer, v. 141, n. 1, p. 47–62, 2017.
- LAMMEY, R. Using the crossref metadata api to explore publisher content. **Science Editing**, Korean Council of Science Editors, v. 3, n. 2, p. 109–111, 2016.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **biometrics**, JSTOR, p. 159–174, 1977.
- LEBOEUF, J. Practical applications of remote sensing technology—an industry perspective. **HortiTech**, 2000.
- LI, C.; BACIU, G.; WANG, Y. Module-based visualization of large-scale graph network data. **Journal of visualization**, Springer, v. 20, n. 2, p. 205–215, 2017.
- LI, H. e. a. Maxent-based modeling and climate change risk assessment for coffea arabica in southwest china. **Environmental and Ecological Statistics**, 2024.
- LOBO, J. M.; JIMÉNEZ-VALVERDE, A.; REAL, R. Assessing the effect of the extent of the study area on the accuracy of species distribution models: a case study with iberian amphibians and reptiles. **Ecological Modelling**, Elsevier, v. 210, n. 3, p. 478–486, 2008.
- LOPES, K. C. M. Alterações químicas em grãos in natura de café arábica de altitude promovidas por fermentação controlada. Alegre, 2025.
- LUZ, M. P. S. *et al.* Aptidão da colheita mecanizada em lavouras cafeeiras no município de carmo de minas, mg. Embrapa Café, 2015.
- MALVINO, S.; SILVA, E. Análise climática do município de patrocínio (mg). **Caminhos de Geografia**, v. 10, n. 16, p. 93–108, 2005.
- MARCO, P. D.; NÓBREGA, C. C. Evaluating collinearity effects on species distribution models: An approach based on virtual species simulation. **PloS one**, Public Library of Science San Francisco, CA USA, v. 13, n. 9, p. e0202403, 2018.
- MERLE, I. *et al.* Microclimate estimation under different coffee-based agroforestry systems using full-sun weather data and shade tree characteristics. **European Journal of Agronomy**, Elsevier, v. 132, p. 126396, 2022.
- MEROW, C.; SMITH, M.; SILANDER, J. A practical guide to maxent for modeling species' distributions: what it does, and why inputs and settings matter. **Ecography**, v. 36, n. 10, p. 1058–1069, 2013.
- MOREIRA, S. L. *et al.* Intercropping of coffee with the palm tree, macauba, can mitigate climate change effects. **Agricultural and forest meteorology**, Elsevier, v. 256, p. 379–390, 2018.
- MUSHTAQ, S. *et al.* Modelled distribution of an invasive alien plant species differs at different spatiotemporal scales under changing climate: a case study of parthenium hysterophorus l. **Tropical Ecology**, Springer, v. 62, n. 3, p. 398–417, 2021.
- NAGENDRA, H. Using remote sensing to assess biodiversity. **International journal of remote sensing**, Taylor & Francis, v. 22, n. 12, p. 2377–2400, 2001.

- NAIR, P. R.; KUMAR, B. M.; NAIR, V. D. **An introduction to agroforestry: four decades of scientific developments**. [S.l.]: Springer, 2021.
- OLIVEIRA, K. R. *et al.* Influence of temperature and altitude on the expansion of coffee crops in matas de minas, brazil. *Revista Engenharia na Agricultura*, 2020.
- OSMAN, K. T. Physical properties of soil. In: **Soils: Principles, properties and management**. [S.l.]: Springer, 2012. p. 49–65.
- OVALLE-RIVERA, O. *et al.* Projected shifts in coffea arabica suitability among major global producing regions due to climate change. **PloS one**, Public Library of Science San Francisco, CA USA, v. 10, n. 4, p. e0124155, 2015.
- PAGE, M. J. *et al.* The prisma 2020 statement: an updated guideline for reporting systematic reviews. **bmj**, British Medical Journal Publishing Group, v. 372, 2021.
- PEARCE, J.; FERRIER, S. Evaluating the predictive performance of habitat models developed using logistic regression. **Ecological modelling**, Elsevier, v. 133, n. 3, p. 225–245, 2000.
- PEBESMA, E. *et al.* Simple features for r. **Journal of Statistical Software**, v. 90, n. 1, p. 1–31, 2018.
- PEDERSEN, T. L. **patchwork: The Composer of Plots**. [S.l.], 2025. R package version 1.3.2. Disponível em: <https://CRAN.R-project.org/package=patchwork>.
- PETERSON, A. T. Predicting the geography of species' invasions via ecological niche modeling. **The quarterly review of biology**, The University of Chicago Press, v. 78, n. 4, p. 419–433, 2003.
- PETERSON, A. T.; SOBERÓN, J. Species distribution modeling and ecological niche modeling: getting the concepts right. **Natureza & Conservação**, v. 10, n. 2, p. 102–107, 2012.
- PETITPIERRE, B. *et al.* Selecting predictors to maximize the transferability of species distribution models: Lessons from cross-continental plant invasions. **Global Ecology and Biogeography**, Wiley Online Library, v. 26, n. 3, p. 275–287, 2017.
- PETTORELLI, N. *et al.* Satellite remote sensing for applied ecologists: opportunities and challenges. **Journal of Applied Ecology**, Wiley Online Library, v. 51, n. 4, p. 839–848, 2014.
- PHILLIPS, S. J.; ANDERSON, R. P.; SCHAPIRE, R. E. Maximum entropy modeling of species geographic distributions. **Ecological modelling**, Elsevier, v. 190, n. 3–4, p. 231–259, 2006.
- PHILLIPS, S. J.; DUDÍK, M. A maximum entropy approach to species distribution modeling. **Proceedings of the Twenty-First International Conference on Machine Learning**, ACM, p. 655–662, 2004.
- PHILLIPS, S. J. *et al.* Sample selection bias and presence-only distribution models: implications for background and pseudo-absence data. **Ecological Applications**, v. 19, n. 1, p. 181–197, 2009.

- PHILLIPS, S. J.; DUDÍK, M.; SCHAPIRE, R. E. Modeling of species distributions with maxent: new extensions and a comprehensive evaluation. **Ecography**, Wiley, v. 31, n. 2, p. 161–175, 2008.
- PHIRI, D. *et al.* Sentinel-2 data for land cover/use mapping: A review. **Remote sensing**, Mdpi, v. 12, n. 14, p. 2291, 2020.
- PIMENTEL-GOMES, F. **Curso de Estatística Experimental**. Piracicaba: FEALQ, 2000.
- POGGIO, L. *et al.* Soilgrids 2.0: producing soil information for the globe with quantified spatial uncertainty. **Soil**, Copernicus Publications Göttingen, Germany, v. 7, n. 1, p. 217–240, 2021.
- QUISPE, K. *et al.* Spatial analysis of soil acidity and available phosphorus in coffee-growing areas of pichanaqui: implications for liming and site-specific fertilization. **Agriculture**, MDPI, v. 15, n. 15, p. 1632, 2025.
- RICE, R. A. Fruits from shade trees in coffee: how important are they? **Agroforestry systems**, Springer, v. 83, p. 41–49, 2011.
- RONG, Z. *et al.* Modeling the effect of climate change on the potential distribution of qinghai spruce (*picea crassifolia* kom.) in qilian mountains. **Forests**, MDPI, v. 10, n. 1, p. 62, 2019.
- SALOMONSON, V.; TOLL, D. spectral band characteristics of the eos moderate resolution imaging spectrometer (modis-n) facility instrument. **Advances in Space Research**, v. 2, n. 3, p. 231–236, 1990.
- SALOMONSON, V. V. *et al.* Modis-advanced facility instrument for studies of the earth as a system. 1987.
- SARVINA, Y. *et al.* Projection of robusta coffee's climate suitability for sustainable indonesian coffee production. **International Journal of Sustainable Development & Planning**, v. 18, n. 4, 2023.
- SCHNEIDER, B. de O.; ALVES, M. de C.; FERREIRA, V. A. Coffee crop detection and mapping using sentinel-2 data and spatial coherence. **Theoretical and Applied Engineering**, v. 9, n. 3, 2025.
- SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, v. 27, n. 3, p. 379–423, 1948.
- SILLERO, N.; BARBOSA, A. M. Common mistakes in ecological niche models. **International Journal of Geographical Information Science**, Taylor & Francis, v. 35, n. 2, p. 213–226, 2021.
- SINGH, P.; SARAN, S.; KOCAMAN, S. Role of maximum entropy and citizen science to study habitat suitability of jacobin cuckoo in different climate change scenarios. **ISPRS International Journal of Geo-Information**, MDPI, v. 10, n. 7, p. 463, 2021.
- SOARES, A. d. S. *et al.* Detecção precoce da ferrugem do cafeeiro causada por *hemileia vastatrix* a partir de imagens multiespectrais. Universidade Federal de Uberlândia, 2022.

SOUZA, C. G. *et al.* Multitemporal variables for the mapping of coffee cultivation areas. **Pesquisa Agropecuária Brasileira**, SciELO Brasil, v. 54, p. e00017, 2019.

STRAHLER, A. *et al.* Modis land cover and land-cover change products algorithm theoretical basis document (atbd). version 5.0. **Center for Remote Sensing, Department of Geography, Boston University, May, 72p**, 1999.

SWETS, J. A. Measuring the accuracy of diagnostic systems. **Science**, American Association for the Advancement of Science, v. 240, n. 4857, p. 1285–1293, 1988.

TAMIMINIA, H. *et al.* Google earth engine for geo-big data applications: A meta-analysis and systematic review. **ISPRS journal of photogrammetry and remote sensing**, Elsevier, v. 164, p. 152–170, 2020.

TEAM, R. C. *et al.* R: A language and environment for statistical computing. **R foundation for statistical computing, Vienna, Austria**, 2021.

THAPA, S. *et al.* Will climate change impact distribution of bats in nepal himalayas? a case study of five species. **Global Ecology and Conservation**, Elsevier, v. 26, p. e01483, 2021.

THENKABAIL, P. S.; LYON, J. G.; HUETE, A. Advances in hyperspectral remote sensing of vegetation and agricultural crops. In: **Fundamentals, sensor systems, spectral libraries, and data mining for vegetation**. [S.l.]: CRC press, 2018. p. 3–37.

THIOUNE, E.-H. *et al.* Temperature impacts the response of coffea canephora to decreasing soil water availability. **Tropical Plant Biology**, Springer, v. 13, p. 236–250, 2020.

TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A review on uav-based applications for precision agriculture. **Information**, MDPI, v. 10, n. 11, p. 349, 2019.

U.S. Department of Agriculture. **Production - Coffee**. 2024. <https://www.fas.usda.gov/data/production/commodity/0711100>. Acesso em: 31 maio 2025.

U.S. Department of Agriculture. **Production - Coffee**. 2024. <https://www.fas.usda.gov/data/production/commodity/0711100>. Acesso em: 31 maio 2025.

VOSSEN, H. Van der; BERTRAND, B.; CHARRIER, A. Next generation variety development for sustainable production of arabica coffee (coffea arabica l.): a review. **Euphytica**, Springer, v. 204, n. 2, p. 243–256, 2015.

WANG, J.; LI, X.; ZHANG, R. Evaluation of the modified chlorophyll absorption in reflectance index (mcari) for crop stress detection using sentinel-2 imagery. **Remote Sensing of Environment**, v. 243, p. 111763, 2020. Este estudo avalia o índice MCARI para detecção de estresse em culturas agrícolas usando dados do Sentinel-2, demonstrando sua eficácia na estimativa de clorofila e saúde da vegetação.

WEI, Y. *et al.* Chinese caterpillar fungus (ophiocordyceps sinensis) in china: Current distribution, trading, and futures under climate change and overexploitation. **Science of the Total Environment**, Elsevier, v. 755, p. 142548, 2021.

WEN, J. *et al.* The main inherent uncertainty sources in trend estimation based on satellite remote sensing data. **Theoretical and Applied Climatology**, Springer, v. 151, n. 1, p. 915–934, 2023.

- WICKHAM, H. ggplot2. **Wiley interdisciplinary reviews: computational statistics**, Wiley Online Library, v. 3, n. 2, p. 180–185, 2011.
- WICKHAM, H.; WICKHAM, M. H. Package ‘plyr’. **A Grammar of Data Manipulation. R package version**, v. 8, 2019.
- XIE, Q.; SUN, Y.; LI, H. Assessment of vegetation reflectance indices for characterizing crop canopy dynamics from multi-sensor remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, v. 78, p. 212–224, 2019. Analisa diferentes índices de vegetação derivados de sensores ópticos e sua relação com a dinâmica do dossel de culturas, incluindo índices sensíveis à clorofila e vigor vegetativo.
- XIONG, X.; BARNES, W. An overview of modis radiometric calibration and characterization. **Advances in Atmospheric Sciences**, Springer, v. 23, n. 1, p. 69–79, 2006.
- XU, N. *et al.* Assessing the suitable cultivation areas for scutellaria baicalensis in china using the maxent model and multiple linear regression. **Biochemical Systematics and Ecology**, Elsevier, v. 90, p. 104052, 2020.
- YANG, J. *et al.* Potential geographic distribution of relict plant pteroceltis tatarinowii in china under climate change scenarios. **Plos One**, Public Library of Science San Francisco, CA USA, v. 17, n. 4, p. e0266133, 2022.
- ZHANG, K.; ZHANG, Y.; TAO, J. Predicting the potential distribution of paeonia veitchii (paeoniaceae) in china by incorporating climate change into a maxent model. **Forests**, MDPI, v. 10, n. 2, p. 190, 2019.
- ZHANG, S. *et al.* Maximum entropy modeling for the prediction of potential plantation distribution of arabica coffee under the cmip6 mode in yunnan, southwest china. **Atmosphere**, MDPI, v. 13, n. 11, p. 1773, 2022.
- ZHEN-JIANG, Q.; GUANG-SHENG, Z. Regionalization of climatic suitability for major kiwifruit cultivars in china. **Chinese Journal of Agrometeorology**, v. 38, n. 04, p. 257, 2017.
- ZHU, Z.; WANG, S.; WOODCOCK, C. E. Improvement and expansion of the fmask algorithm: Cloud, cloud shadow, and snow detection for landsats 4–7, 8, and sentinel 2 images. **Remote sensing of Environment**, Elsevier, v. 159, p. 269–277, 2015.

3 ARTIGO 1 – MODELAGEM DO CULTIVO DE CAFÉ USANDO MAXENT: ABORDAGENS E DESAFIOS

3.1 Abordagem metodológica de busca de artigos de modelagem MaxEnt na cafeicultura

A busca bibliográfica foi realizada no software R (v4.5.1) (Team *et al.*, 2021), utilizando os pacotes (rcrossref, V:1.2.1) (Lammey, 2016), (bibliometrix, V:5.2.1) (Aria; Cuccurullo, 2017), (dplyr, V:1.2.0) (Wickham; Wickham, 2019) e (DiagrammeR, V:1.0.11) (Li; Baciú; Wang, 2017), seguindo as diretrizes do PRISMA 2020 (Page *et al.*, 2021) conforme mostrado na Figura 7.1 do apêndice A. Foram buscados artigos revisados por pares publicados entre 2015 e 2025 em três bases de dados: Crossref (termo de busca *Modelagem MaxEnt Coffea*), *Web of Science e Scopus* (ambas com o termo *Coffee MaxEnt modelling*), restringindo-se a artigos de periódicos. Os procedimentos completos e os scripts utilizados estão disponíveis no GitHub: <https://geoprocessingcuna.github.io/MaxentRef/>.

Os registros provenientes das três bases foram combinados e tiveram as duplicatas removidas em duas etapas: correspondência exata por DOI; e correspondência aproximada de títulos utilizando chaves normalizadas e algoritmos de distância entre cadeias de caracteres.

Após a remoção de duplicatas, filtros automáticos foram aplicados para excluir estudos fora do escopo, incluindo trabalhos relacionados a espécies não pertinentes, química/genética e temas de pós-colheita. Em seguida, realizou-se a triagem manual de títulos e resumos, com base nos critérios abaixo:

- **Inclusão:** estudos envolvendo *Coffea arabica* ou *Coffea canephora* que aplicaram MaxEnt ou outros Modelos de Distribuição de Espécies (MDEs) para distribuição geográfica, adequabilidade climática, projeções futuras ou zoneamento agroclimático.
- **Exclusão:** estudos não relacionados ao café, publicações não revisadas por pares ou trabalhos focados exclusivamente em química, genética ou processamento.

O processo resultou em um total de 556 registros iniciais, porém apenas 21 estudos foram incluídos na síntese final. O fluxograma PRISMA Figura 7.1 do apêndice A, foi gerado no software R utilizando o pacote DiagrammeR e apresenta o fluxo da busca e seleção dos artigos incluídos na revisão, conforme apresentado na Tabela 7.2.

Ao longo da última década, diversos estudos utilizaram a modelagem MaxEnt (Máxima Entropia) para investigar os impactos das mudanças climáticas sobre o cultivo do café. Esses trabalhos abrangem diferentes regiões geográficas, cenários climáticos e abordagens metodológicas, fornecendo importantes contribuições sobre a adequabilidade futura, zoneamento agroclimático, riscos de pragas e doenças, e estratégias de adaptação.

3.2 Etapas da modelagem MaxEnt no café

A modelagem da distribuição espacial de lavouras cafeeiras é realizada por meio da sobreposição espacial ponderada de variáveis ambientais, utilizando ferramentas de SIG (Fain *et al.*, 2018). Essa abordagem integra diferentes camadas temáticas que representam fatores bióticos e abióticos relacionados ao cultivo, como variáveis ambientais, espectrais, biofísicas e edáficas. O processo de modelagem envolve as seguintes etapas: Aquisição dos dados; Preparação dos dados; Otimização do modelo; Calibração do modelo; Execução do modelo; Validação cruzada; Avaliação final de desempenho; Geração do mapa de probabilidade.


3.3 Obtenção de dados de ocorrência de café

Analizando os dados provenientes dos 21 artigos selecionados conforme a Tabela 7.2, constatou-se que diversos registros foram obtidos em bases públicas, como o *Global Biodiversity Information Facility (GBIF)*, o *Centre for Agriculture and Bioscience International (CABI)*, coleções de herbários (Abigaba *et al.*, 2024), o *International Center for Tropical Agriculture (CIAT)*, o *Instituto Brasileiro de Geografia e Estatística (IBGE)*, a *Ethiopian Coffee and Tea Development Authority (ECTDA)* (Adane, 2024) e a *Secretaría de Agricultura y Desarrollo Rural do México (SAGARPA)*.

Além disso, outras fontes incluíram coletas de campo com GPS (Hailu *et al.*, 2017; Oliveira *et al.*, 2020; Läderach *et al.*, 2017), entrevistas com produtores rurais e interpretação visual de imagens de satélite, como as disponíveis no Google Earth.

O uso combinado de diferentes fontes, conforme demonstrado por (Bunn, 2015a), (Jiménez *et al.*, 2023) e (Li, 2024), mostrou-se eficaz para representar de forma mais fiel a distribuição espacial das áreas cultivadas, reduzindo as limitações inerentes a cada base de dados.

Figura 3.1 – Principais fontes de dados de presença utilizadas na modelagem MaxEnt em cafeicultura.



Fonte: Elaborado pelo autor (2026).

A Figura 3.1 ilustra as principais fontes de dados utilizadas nos estudos analisados. Observa-se que a maioria dos trabalhos utilizou dados de campo, fator positivo para a qualidade dos modelos. Também se verifica que, na maior parte dos casos, múltiplas fontes de dados foram combinadas. Por exemplo, (Abigaba *et al.*, 2024) utilizaram registros obtidos entre 2005 e 2020, provenientes do GBIF e de revisões de literatura. Em relação ao número de registros de presença, observa-se uma variação entre 44 e 9.280 pontos nos modelos analisados.

3.4 Preparação de dados

Os dados de presença da cultura do café constituem a base primária para a modelagem com o algoritmo MaxEnt. Cada registro deve conter coordenadas geográficas precisas, geralmente representadas por:

$$x_i = (\text{lat}_i, \text{lon}_i),$$

em que x_i corresponde ao ponto i de ocorrência da cultura no espaço geográfico.

Para garantir a qualidade e a representatividade dos dados de entrada, recomenda-se realizar a preparação de dados, que consiste em:

- Eliminar registros duplicados, imprecisos ou localizados muito próximos entre si, evitando sobreajuste (*overfitting*) do modelo;
- Verificar a consistência geográfica dos registros com o auxílio de ferramentas como *Google Earth* ou *Google Maps* (Abigaba *et al.*, 2024);
- Armazenar os dados em formato *.csv*, com colunas para latitude, longitude e, opcionalmente, atributos adicionais (como data, fonte e tipo de ocorrência), facilitando a integração com o software Maxent (Li, 2024; Zhang *et al.*, 2022).

Pontos de fundo (*background points*) são gerados a uma distância mínima (1 km para o presente estudo) dos pontos de presença, evitando sobreposição. O conjunto de fundo inclui toda a área de estudo, de onde são extraídas informações que caracterizam o ambiente acessível à espécie (Sillero; Barbosa, 2021). Conforme definição de (Phillips *et al.*, 2009), os dados de fundo não correspondem a tentativas de “adivinhar” locais de ausência, mas sim a uma forma de caracterizar os ambientes na região estudada (AMARO *et al.*,). Nesse sentido, o contexto ambiental é o mesmo, independentemente de onde a espécie foi encontrada. Os dados de *background* estabelecem o domínio ambiental do estudo, enquanto os dados de presença indicam sob quais condições a espécie tem maior probabilidade de ocorrer em relação à média (Hijmans; Elith, 2021).

3.5 Otimização do modelo

A otimização do modelo consistiu na extração (reamostragem) dos valores das variáveis preditoras nos pontos de ocorrência e na filtragem dessas variáveis para evitar multicolinearidade. Variáveis preditoras são aquelas utilizadas para explicar a presença do café em determinado local, incluindo índices espectrais, variáveis ambientais, altitude e atributos do solo.

A seleção dos preditores ambientais foi realizada nas plataformas GEE e *R*, v4.5.1, utilizando o pacote *ggcorrplot*, V: 0.1.4.1 (Kassambara; Kassambara, 2019). O procedimento visa minimizar os efeitos da multicolinearidade, eliminando preditores redundantes (Feng *et al.*, 2019; Dormann *et al.*, 2013; Cohen *et al.*, 2009; Marco; Nóbrega, 2018).

A colinearidade foi avaliada por meio do coeficiente de correlação de Pearson:

$$r_{XY} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}, \quad (3.1)$$

em que $\text{cov}(X, Y)$ representa a covariância entre X e Y , e σ_X e σ_Y são os respectivos desvios-padrão. Variáveis com correlação absoluta superior a 0,8 foram consideradas colineares e, portanto, candidatas à exclusão do conjunto de preditores (Dormann *et al.*, 2013):

$$|r_{XY}| > 0.8. \quad (3.2)$$

Além do critério estatístico, a escolha final dos preditores considerou sua relevância ecológica, priorizando variáveis diretamente associadas a fatores climáticos, topográficos e espectrais que influenciam o desenvolvimento e a produtividade do café (Petitpierre *et al.*, 2017).


Devido à relevância dessas variáveis, sua incorporação em modelos preditivos exige dados confiáveis e de alta resolução espacial. Os estudos analisados utilizaram principalmente variáveis climáticas, topográficas e edáficas (Figura 3.2). As variáveis climáticas foram obtidas a partir da base *WorldClim* (Fick; Hijmans, 2017), com resolução espacial de 2,5 minutos de arco. Esse conjunto de dados já é ajustado para viés climático pelo método delta, com base em observações meteorológicas de mais de 47.000 estações globais no período de 1950 a 2000 (Bunn, 2015a; Ovalle-Rivera *et al.*, 2015).

3.5.1 Variáveis bioclimáticas

Modelos climáticos globais do CMIP6 refinam essas variáveis com resolução espacial de até 30 segundos de arco (aproximadamente 1 km²). Os dados históricos representam a média do período 1970–2000, enquanto as projeções de médio prazo correspondem ao período 2041–2060, simuladas por cinco Modelos de Circulação Global (GCMs): CanESM5, MRI-ESM2-0, MIROC6, UKESM1-0-LL e CNRM-CM6-1 (Sarvina *et al.*, 2023).

Os cenários socioeconômicos compartilhados (Shared Socioeconomic Pathways – SSP) combinados às trajetórias de concentração representativa (RCP) foram amplamente utilizados para projeções climáticas. Os cenários considerados incluem SSP1–RCP2.6, SSP2–RCP4.5, SSP3–RCP7.0 e SSP5–RCP8.5. Entre as variáveis mais utilizadas como preditoras destacam-se BIO12, BIO15, BIO6 e BIO16, determinantes para ecossistemas cafeeiros.

Figura 3.2 – Preditores mais utilizados na modelagem do café com MaxEnt.



Fonte: Elaborado pelo autor (2026).

Das variáveis bioclimáticas empregadas nos 21 estudos analisados, aquelas que mais se destacaram como preditoras da aptidão climática conforme, (Figura 3.2) do café arábica (*Coffea arabica*) foram BIO12 (precipitação anual), BIO15 (sazonalidade da precipitação) e BIO6 (temperatura mínima do mês mais frio), em virtude de seu papel direto sobre processos fisiológicos, fenológicos e produtivos da planta. Em modelagens de distribuição climática realizadas com MaxEnt e outros algoritmos, a precipitação anual (BIO12) e a sazonalidade da precipitação (BIO15) foram frequentemente identificadas entre as variáveis climáticas de maior contribuição para explicar a adequação ambiental do cafeeiro, indicando que a quantidade total de chuva e sua distribuição ao longo do ano influenciam diretamente a disponibilidade de água para crescimento, floração, enchimento de grãos e resistência ao estresse hídrico (em muitos modelos, Bio12 e Bio15 figuraram entre as variáveis mais importantes para aptidão climática) (Chalchissa; Diga; Tolossa, 2022).

A disponibilidade e distribuição da água ao longo do ano, representadas por BIO12 e BIO15, influenciam diretamente o balanço hídrico das plantas, afetando a fotossíntese, o desenvolvimento vegetativo e produtivo, e determinando a probabilidade de ocorrência de estresse hídrico em fases críticas do ciclo produtivo do cafeeiro, o que pode reduzir produtividade e qualidade da colheita. Estudos de modelagem climática realizados em diferentes regiões mostram

Tabela 3.1 – Variáveis bioclimáticas disponibilizadas pela base WorldClim.

Código	Descrição
BIO1	Temperatura média anual
BIO2	Amplitude térmica média diurna
BIO3	Isotermalidade
BIO4	Sazonalidade da temperatura
BIO5	Temperatura máxima do mês mais quente
BIO6	Temperatura mínima do mês mais frio
BIO7	Amplitude térmica anual (BIO5–BIO6)
BIO8	Temperatura média do trimestre mais úmido
BIO9	Temperatura média do trimestre mais seco
BIO10	Temperatura média do trimestre mais quente
BIO11	Temperatura média do trimestre mais frio
BIO12	Precipitação anual
BIO13	Precipitação do mês mais úmido
BIO14	Precipitação do mês mais seco
BIO15	Sazonalidade da precipitação (coeficiente de variação)
BIO16	Precipitação do trimestre mais úmido
BIO17	Precipitação do trimestre mais seco
BIO18	Precipitação do trimestre mais quente
BIO19	Precipitação do trimestre mais frio

Fonte: Elaborado pelo autor com base em dados do Wordclim.

que variáveis relacionadas à precipitação são fundamentais para explicar tanto a distribuição atual quanto projeções futuras da cultura sob cenários de mudança climática (Chalchissa; Diga; Tolossa, 2022) .

A temperatura mínima do mês mais frio (BIO6) também é relevante porque o *C. arabica* é sensível a extremos térmicos, especialmente durante períodos noturnos frios ou excessivamente quentes. Temperaturas mínimas influenciam processos fisiológicos básicos — como respiração, manutenção de tecidos e limites de tolerância térmica — e estão associadas a condições que podem comprometer o desenvolvimento vegetativo e reprodutivo quando ultrapassadas. Embora alguns estudos nacionais e regionais indiquem variações na importância relativa de

BIO6 dependendo da região estudada, a sensibilidade do café arábica a variações térmicas, especialmente mínimas, é um fator reconhecido na modelagem climática da espécie (Chalchissa; Diga; Tolossa, 2022).

Modelos de distribuição climática que analisam cenários atuais e futuros frequentemente realçam que o conjunto de variáveis relacionadas à precipitação e à temperatura mínima configuram a base para delimitar áreas adequadas ao cultivo sob diferentes condições climáticas, destacando que temperaturas muito baixas ou variações extremas reduzem a aptidão climática do cafeeiro (Chalchissa; Diga; Tolossa, 2022).

Além disso, projeções recentes indicam que alterações nos padrões de precipitação e aumentos nas temperaturas mínimas, associados a mudanças climáticas globais, podem afetar negativamente a produtividade e a qualidade do café arábica, pois desviam as condições climáticas fora das faixas ótimas para a cultura (por exemplo, precipitação anual tipicamente superior a 1200–1500 mm e temperaturas moderadas), prejudicando a sincronização da floração e o enchimento dos grãos. Em conjunto, estas evidências reforçam que extremos térmicos e desequilíbrios hídricos — representados por BIO6, BIO12 e BIO15 — são variáveis bioclimáticas críticas na compreensão da resposta do *Coffea arabica* às mudanças climáticas, justificando sua recorrente seleção em modelos de distribuição e impacto climático para a espécie (Chalchissa; Diga; Tolossa, 2022).

3.5.2 Variáveis topográficas

Os estudos também utilizaram variáveis topográficas derivadas da missão Shuttle Radar Topography Mission (SRTM) da USGS EarthExplorer, tais como altitude, orientação de encosta (aspect), sombreamento do relevo (hillshade) e declividade, para caracterizar o ambiente físico das áreas de cultivo do café (Sarvina *et al.*, 2023). Dentre essas, a altitude, conforme (Figura 3.2) foi a variável altimétrica mais frequentemente empregada, presente em nove estudos, o que reflete a forte relação entre elevação e o desempenho agrônômico do café. Estudos agrônômicos e de modelagem indicam que o café arábica (*Coffea arabica*) geralmente apresenta melhor desempenho em altitudes elevadas, em comparação com *Coffea canephora*, que tende a ser cultivado em altitudes mais baixas, em função das diferenças climáticas e de metabolismo das espécies (Lopes, 2025).

A altitude influencia diretamente a temperatura média e a variação térmica diurna, fatores determinantes para o ciclo de maturação dos frutos, a concentração de açúcares e compostos aromáticos nos grãos, bem como atributos de qualidade sensorial da bebida produzida (Lopes, 2025). Além disso, a altitude também afeta propriedades do solo, da microbiota rizosférica e da fertilidade, que podem promover condições mais favoráveis ao desenvolvimento saudável das plantas e à qualidade do café produzido em altitudes médias a elevadas (Barros; Moreira; Rudorff, 2007). Em altitudes maiores, uma variação térmica mais acentuada entre dia e noite é comum, o que pode favorecer a formação de compostos relacionados ao aroma e à qualidade da bebida (Luz *et al.*, 2015).

A declividade do terreno, por sua vez, não só representa um aspecto geomorfológico importante do ambiente de cultivo, como também exerce influência direta na mecanização agrícola e nos custos operacionais. A declividade é uma das principais características que limitam o uso de máquinas agrícolas na cafeicultura, pois terrenos mais inclinados dificultam a circulação, estabilidade e segurança de tratores e colhedoras, e podem exigir operações mais lentas, adaptações especiais ou mão-de-obra adicional (Barros; Moreira; Rudorff, 2007; Alves; Pereira; Dalchiavon, 2017). Estudos de aptidão à mecanização mostram que terrenos com declividades menores (tipicamente até cerca de 10–15 %) são mais adequados para a mecanização de tratos culturais e colheita, enquanto áreas de maior declive tendem a restringir ou inviabilizar determinadas operações mecanizadas (Barros; Moreira; Rudorff, 2007; Alves; Pereira; Dalchiavon, 2017). Por exemplo, áreas com declividade inferior a 10–15% são frequentemente classificadas como aptas à mecanização, enquanto declividades acima desse limiar podem exigir terraces, práticas de adaptação ou manutenção de manejo manual (o que eleva os custos de produção) (Barros; Moreira; Rudorff, 2007; Alves; Pereira; Dalchiavon, 2017).

A orientação de encosta (aspect) também influencia a incidência de radiação solar e microclimas locais, o que pode afetar a fotossíntese, evapotranspiração e o desenvolvimento vegetativo das plantas — aspectos que em conjunto com a topografia podem modificar as demandas por manejo e impacto econômico das operações agrícolas.

Dessa forma, as variáveis altimétricas e topográficas — como altitude e declividade — se evidenciam nos estudos por sua capacidade de representar características fundamentais do ambiente físico que influenciam tanto o desenvolvimento fisiológico e produtivo quanto aspectos operacionais e custo da mecanização, justificando sua inclusão recorrente em modelagens de distribuição climática, aptidão climática e planejamento agrícola para o cultivo do café arábica.

3.5.3 Variáveis espectrais

Estudos recentes (Zhang *et al.*, 2022) têm incorporado índices espectrais derivados de imagens de satélite como variáveis preditoras em modelos de aptidão climática e produtividade do café. Imagens de satélite de alta resolução, como Sentinel-2, Landsat-8 e MODIS, permitem a extração de informações sobre fenologia das plantas, vigor vegetativo e disponibilidade hídrica, fornecendo indicadores indiretos do estado fisiológico das culturas e das condições ambientais locais.

Entre os índices avaliados nos estudos, o NDVI (Normalized Difference Vegetation Index) foi o mais utilizado conforme (Figura 3.2). O NDVI reflete a quantidade e a saúde da vegetação, sendo sensível a alterações no crescimento e na cobertura das plantas, além de indicar níveis de estresse hídrico. A inclusão de índices espectrais como o NDVI melhora significativamente o desempenho de modelos de previsão e distribuição climática, aumentando a precisão na detecção de áreas aptas ao cultivo e na estimativa de produtividade (Hailu *et al.*, 2017; Gomes *et al.*, 2020).

Dessa forma, a combinação de variáveis climáticas, topográficas e índices espectrais permite uma representação mais completa do ambiente de cultivo do café, capturando não apenas fatores estáticos, como altitude e declividade, mas também dinâmicas fenológicas e de saúde das plantas, o que fortalece a capacidade preditiva dos modelos e o planejamento de manejo agrícola.

3.5.4 Variáveis edáficas

Dentre os atributos do solo, destacam-se dados obtidos a partir de bases globais como a Harmonized World Soil Database (HWSD 2.0), que provê informações detalhadas sobre propriedades do solo em resolução espacial contínua úteis em modelagem ambiental e agrícola (Canton, 2021), e o SoilGrids (ISRIC), um sistema global de mapeamento digital de solos que gera predições espaciais para propriedades como pH, textura (frações de areia, silte e argila), carbono orgânico, capacidade de troca catiônica (CTC) e densidade do solo (Hengl *et al.*, 2017; Poggio *et al.*, 2021). Esses atributos incluem pH do solo, carbono orgânico, textura, capacidade de troca catiônica (CTC), saturação por alumínio e nutrientes disponíveis (P, K, N), que são

reconhecidos como determinantes para a disponibilidade de nutrientes e a saúde das plantas em sistemas de produção agrícola (Giraldo-Sanclemente *et al.*, 2025).

Embora variáveis do solo sejam menos frequentemente usadas em comparação com variáveis climáticas e topográficas em modelos de distribuição e aptidão climática do café, essas variáveis edáficas possuem elevada importância agronômica, pois influenciam diretamente a nutrição, o estado hídrico e o desenvolvimento radicular da planta (Giraldo-Sanclemente *et al.*, 2025). Por exemplo, o pH do solo modula a disponibilidade de nutrientes essenciais — solos ligeiramente ácidos (em torno de 5,5–6,5) são geralmente considerados ideais para o crescimento do café arábica, pois favorecem a solubilidade de fósforo e outros elementos essenciais (Giraldo-Sanclemente *et al.*, 2025).

Dos atributos do solo analisados nos estudos avaliados, os mais frequentemente empregados como preditores foram o pH do solo (pHsoil) e a fração de silte (silt) conforme (Figura 3.2). O pH do solo é crítico para controlar a disponibilidade de nutrientes e a atividade de microrganismos benéficos no solo, interferindo diretamente no crescimento, na absorção de nutrientes e na produtividade das plantas (Giraldo-Sanclemente *et al.*, 2025; Quispe *et al.*, 2025). A fração de silte, por sua vez, faz parte da textura do solo, que influencia a retenção de água, a aeração, a capacidade de infiltração e a disponibilidade de água no solo, aspectos que condicionam a capacidade das raízes em explorar o solo e obter água e nutrientes em períodos críticos do ciclo produtivo (Osman, 2012).

Assim, mesmo que menos utilizados do que variáveis climáticas como temperatura e precipitação, índices edáficos como pH e silte são incorporados em alguns estudos porque capturam características fundamentais do ambiente do solo que afetam tanto o desenvolvimento vegetativo quanto a produtividade e qualidade da cultura do café arábica.

3.5.5 Outras variáveis

Outras variáveis menos frequentes incluíram radiação solar, velocidade do vento, índice de influência humana (HII) e densidade de pontos de ocorrência de *Coffea spp.* (CDP), importantes para representar condições ambientais heterogêneas e impactos antrópicos, como na previsão de disseminação de doenças (Geronimo-Isidro *et al.*, 2025), conforme (Figura 3.2).

3.6 Avaliação dos Modelos

A avaliação da capacidade discriminativa global dos modelos foi realizada principalmente por meio da Área Sob a Curva ROC (AUC). A curva *Receiver Operating Characteristic* (ROC) descreve a relação entre a taxa de verdadeiros positivos (*True Positive Rate* – TPR) e a taxa de falsos positivos (*False Positive Rate* – FPR) para todos os limiares possíveis.

A AUC é definida como:

$$AUC = \int_0^1 TPR(t) dFPR(t) \quad (3.3)$$

Essa métrica é independente de limiar e varia de 0,5 (desempenho aleatório) a 1,0 (discriminação perfeita). Valores entre 0,7–0,8 são considerados aceitáveis, 0,8–0,9 bons e acima de 0,9 excelentes (Lobo; Jiménez-Valverde; Real, 2008).

Nos 21 estudos analisados, os valores de AUC variaram entre 0,77 e 0,99, indicando desempenho de aceitável a excelente na distinção entre áreas ambientalmente adequadas e inadequadas para o cultivo de *Coffea*.

Apesar de sua ampla utilização, a AUC possui limitações: pode ser influenciada pela extensão da área de fundo e não diferencia erros de omissão e comissão, devendo ser interpretada como uma medida de discriminação geral e não como indicador único de qualidade preditiva (Lobo; Jiménez-Valverde; Real, 2008).

3.7 Validação dos modelos

A validação dos modelos foi complementada por métricas dependentes de limiar, derivadas da matriz de confusão, que permitem avaliar o desempenho preditivo em termos de acertos e erros de classificação.

3.7.1 Matriz de confusão

	Presença Real	Ausência Real
Presença Prevista	Verdadeiro Positivo (VP)	Falso Positivo (FP)
Ausência Prevista	Falso Negativo (FN)	Verdadeiro Negativo (VN)

3.7.2 Métricas de validação

- Sensibilidade (TPR) mede a capacidade do modelo em prever corretamente presenças:

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (3.4)$$

- Especificidade (TNR) mede a capacidade de prever corretamente ausências:

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (3.5)$$

Essas duas métricas diferenciam tipos de erro: sensibilidade está associada a erros de omissão (FN), enquanto especificidade reflete erros de comissão (FP).

- Acurácia representa a proporção total de classificações corretas:

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.6)$$

Entretanto, pode ser inflada quando há desbalanceamento entre presenças e ausências.

- True Skill Statistic (TSS) combina sensibilidade e especificidade:

$$\text{TSS} = \text{Sensibilidade} + \text{Especificidade} - 1 \quad (3.7)$$

Varia de -1 a +1, onde valores próximos de 1 indicam alta performance. É considerado mais robusto à prevalência da espécie (Allouche; Tsoar; Kadmon, 2006).

- Kappa de Cohen mede a concordância entre observado e previsto além do acaso:

$$\kappa = \frac{p_o - p_e}{1 - p_e} \quad (3.8)$$

onde p_o é a acurácia observada e p_e a acurácia esperada ao acaso . Diferentemente do TSS, o Kappa pode ser sensível à prevalência.

Parte dos 21 estudos avaliados empregou métricas como TSS, Kappa, sensibilidade, especificidade e acurácia para complementar a AUC, permitindo uma avaliação mais detalhada dos tipos de erro e da confiabilidade das previsões.

Essa abordagem combinada é recomendada porque:

- A AUC avalia a discriminação geral do modelo (avaliação);
- Métricas da matriz de confusão medem o desempenho de classificação sob um limiar definido (validação);
- O TSS é menos sensível à prevalência;
- O Kappa considera concordância além do acaso;
- Sensibilidade e especificidade distinguem omissões e comissões.

Assim, a integração entre AUC e métricas derivadas da matriz de confusão fornece uma avaliação mais robusta da qualidade dos modelos de distribuição do café arábica, evitando interpretações baseadas em uma única estatística (Lobo; Jiménez-Valverde; Real, 2008; Allouche; Tsoar; Kadmon, 2006).

3.8 Mapas de probabilidade de ocorrência de cultivos

Os modelos geram como saída principal mapas contínuos de probabilidade de ocorrência de áreas cultivadas com café, nos quais cada pixel recebe um valor entre 0 e 1. Esses valores indicam o grau de similaridade entre as condições ambientais locais e aquelas observadas em locais onde o cultivo de café está presente, refletindo a probabilidade espacial de ocorrência do cultivo.

Esses mapas contínuos permitem identificar padrões espaciais da cafeicultura, zonas de maior concentração de cultivos e áreas marginais onde o cultivo ocorre sob condições ambientais menos favoráveis. Além disso, possibilitam avaliar deslocamentos espaciais de áreas cultivadas sob cenários de mudança climática ou alterações no uso da terra.

Para aplicações quantitativas — como estimativa de área cultivada, análise de expansão ou retração do cultivo e comparações entre cenários — é comum converter essas superfícies contínuas em mapas binários (cultivo/não cultivo) por meio da definição de um limiar de corte.

Um dos métodos estatisticamente mais robustos para definir esse limiar é o índice de Youden (Fielding; Bell, 1997). Esse critério identifica o valor de probabilidade que maximiza simultaneamente sensibilidade e especificidade:

$$J = \text{Sensibilidade} + \text{Especificidade} - 1 \quad (3.9)$$

O limiar ótimo é dado por:

$$t^* = \arg \max_t (\text{Sensibilidade}(t) + \text{Especificidade}(t) - 1) \quad (3.10)$$

Nesse contexto, a sensibilidade representa a proporção de áreas efetivamente cultivadas corretamente identificadas pelo modelo, enquanto a especificidade indica a proporção de áreas sem cultivo corretamente classificadas como ausência.

A utilização do limiar baseado no índice de Youden apresenta vantagens relevantes para o mapeamento de cultivos:

- É um critério objetivo e reproduzível, baseado no desempenho estatístico do modelo;
- Equilibra erros de omissão (não detectar áreas cultivadas) e erros de comissão (classificar como cultivo áreas onde ele não ocorre);
- É menos sensível à prevalência do que métricas como acurácia ou Kappa (Allouche; Tsoar; Kadmon, 2006);
- Produz mapas binários mais consistentes para estimativas de área cultivada e análises comparativas entre períodos ou cenários ambientais (Jiménez-Valverde, 2008).

Após a aplicação do limiar t^* , os mapas passam a representar:

- Áreas com cultivo de café: pixels com probabilidade $\geq t^*$;
- Áreas sem cultivo de café: pixels com probabilidade $< t^*$.

Esses mapas binários permitem quantificar a extensão espacial do cultivo, avaliar padrões de expansão ou retração e apoiar análises de dinâmica agrícola. Como o limiar influencia


diretamente a área classificada como cultivo, a adoção de um critério estatístico como o índice de Youden garante maior rigor, transparência e reprodutibilidade na conversão de probabilidades contínuas em classes discretas.

4 ARTIGO 2 – INTEGRANDO VARIÁVEIS PREDITORAS MULTITEMPORAIS PARA PREVER ÁREAS DE CULTIVO DE CAFÉ USANDO A TÉCNICA MAXENT

4.1 Área de estudo

O estudo foi conduzido nos municípios de Nepomuceno e Patrocínio, localizados no estado de Minas Gerais, Brasil (Figura 4.1). Ambos os municípios destacam-se nacionalmente pela expressiva produção de *Coffea arabica*, inserindo-se entre importantes regiões cafeeiras do estado (Instituto Brasileiro de Geografia e Estatística (IBGE), 2022).

Figura 4.1 – Municípios de Nepomuceno e Patrocínio, Minas Gerais – Brasil.



Fonte: Elaborado pelo autor com base em dados do IBGE (2022).

O município de Nepomuceno está situado na região Sul de Minas Gerais, aproximadamente nas coordenadas 21°14'S e 45°14'W, apresentando altitudes predominantes entre 850 m e 1.050 m. Segundo a classificação climática de Köppen, predomina o clima do tipo Cwa, caracterizado por verões quentes e úmidos e invernos secos e amenos. A precipitação média anual varia entre 1.300 mm e 1.600 mm, enquanto as temperaturas médias anuais oscilam entre 18 °C e 22 °C, condições consideradas favoráveis ao desenvolvimento do cafeeiro arábica.

O município de Patrocínio, localizado na região do Alto Paranaíba (MG), situa-se aproximadamente nas coordenadas 18°55'00"S e 46°58'00"W, com altitude média de 960 m e área

territorial aproximada de 2.838 km² (MALVINO; SILVA, 2005). A região integra a área do Cerrado Mineiro, caracterizada por elevada tecnificação agrícola, mecanização da cafeicultura e forte representatividade econômica da produção cafeeira.

4.2 Materiais e métodos

4.2.1 Fonte de dados

Os dados de ocorrência do café utilizados na modelagem foram obtidos por diferentes estratégias conforme a disponibilidade de informações em cada município.

Para o município de Nepomuceno, foram utilizados arquivos vetoriais no formato *shapefile* contendo polígonos (2481 polígonos) de áreas cultivadas com café referentes ao ano de 2018. Esses dados foram obtidos a partir de colaboradores vinculados a projetos anteriores de mapeamento agrícola regional. Posteriormente, os polígonos foram validados visualmente no software Google Earth Pro, utilizando imagens de alta resolução espacial referentes ao mesmo período (2018), visando garantir consistência espacial e compatibilidade entre as áreas mapeadas e os cultivos efetivamente observados.

Após a validação visual, os polígonos foram importados para o ambiente do Google Earth Engine (GEE), plataforma amplamente utilizada em análises geoespaciais em larga escala devido à sua elevada capacidade de processamento em nuvem (Gorelick *et al.*, 2017). Os polígonos foram armazenados como *FeatureCollection* e submetidos a operações de recorte espacial utilizando as funções *filterBounds()* e *intersection()*, garantindo compatibilidade geométrica com os limites municipais oficiais do IBGE.

Posteriormente, os polígonos foram convertidos em pontos de presença por meio da função *centroid()*, gerando amostras pontuais representativas das áreas cafeeiras. A utilização de centroides é frequentemente empregada em modelagens ambientais e ecológicas visando reduzir redundâncias espaciais associadas à geometria dos polígonos e padronizar a distribuição das amostras (Elith *et al.*, 2011; Phillips; Anderson; Schapire, 2006).

Para o município de Patrocínio, os dados de ocorrência foram obtidos diretamente no ambiente do Google Earth Engine por interpretação visual de imagens orbitais de alta resolução, totalizando 1.091 pontos de presença. A interpretação visual foi realizada considerando padrões espectrais, textura, organização espacial e características estruturais típicas da cafeeira.

cultura regional. Essa abordagem é amplamente utilizada em estudos de modelagem espacial quando inexistem bases vetoriais consolidadas ou quando se busca elevada precisão na identificação dos alvos agrícolas (Phillips; Anderson; Schapire, 2006; Elith *et al.*, 2011).

Os limites municipais utilizados na delimitação das áreas de estudo foram obtidos junto ao IBGE, assegurando padronização cartográfica e compatibilidade espacial entre todos os conjuntos de dados empregados.

Com o objetivo de reduzir autocorrelação espacial e minimizar viés amostral decorrente da concentração excessiva de registros em determinadas áreas, foi aplicado um filtro de distância mínima de 1 km entre os pontos de presença. Esse procedimento foi realizado no ambiente do Google Earth Engine mediante operações geométricas baseadas na criação de zonas de exclusão (*buffers*) ao redor das amostras (Sillero; Barbosa, 2021).

Após a filtragem espacial, foram gerados pontos de fundo (*background points*), amplamente empregados em modelos de máxima entropia (*MaxEnt*) como representação do ambiente disponível na região de estudo (Phillips *et al.*, 2009). Inicialmente, foi criado um buffer de exclusão de 1000 m ao redor dos pontos de presença utilizando a função `buffer()`, seguido da união espacial dessas áreas por meio da função `union()`. Em seguida, a área disponível para geração dos pontos de fundo foi obtida utilizando a função `difference()`, correspondente à diferença espacial entre o limite municipal e as áreas de exclusão.

Os pontos de fundo foram então gerados aleatoriamente por meio da função `random-Points()`, respeitando os limites espaciais definidos e evitando sobreposição com os pontos de presença. Esse procedimento é recomendado em modelagens de distribuição potencial devido à necessidade de representar adequadamente o espaço ambiental disponível ao modelo (Phillips *et al.*, 2009).

4.2.2 Seleção das variáveis preditoras

As variáveis ambientais utilizadas na modelagem foram agrupadas em três categorias principais: variáveis bioclimáticas, topográficas e espectrais. Todo o processamento inicial, extração das variáveis ambientais e preparação das amostras foi realizado no ambiente do GEE, utilizando a linguagem JavaScript.

As variáveis bioclimáticas foram obtidas da base *WorldClim* versão 1 (Hijmans *et al.*, 2005; Fick; Hijmans, 2017), por meio da coleção *WORLDCLIM/V1/BIO*. Foram utilizadas as 19

variáveis bioclimáticas derivadas de médias históricas de temperatura e precipitação Figura 3.1, amplamente empregadas em modelagem ecológica por sintetizarem gradientes ambientais relacionados à distribuição espacial de espécies e cultivos agrícolas (Hijmans *et al.*, 2005).

As variáveis topográficas foram derivadas do Modelo Digital de Elevação SRTM (*Shuttle Radar Topography Mission*), disponibilizado pela coleção *USGS/SRTMGL1/003*. Utilizando o algoritmo *Terrain()*, foram obtidas as variáveis elevação, declividade (*slope*), orientação de vertentes (*aspect*) e sombreamento do relevo (*hillshade*).

Adicionalmente, foi calculado o Índice Topográfico de Umidade (*Topographic Wetness Index* – TWI), amplamente utilizado em estudos hidrológicos e ambientais por representar potenciais zonas de acúmulo de umidade no relevo (Beven; Kirkby, 1979). O cálculo do TWI foi realizado a partir da relação entre o fluxo acumulado e a tangente da declividade Figura 7.1, utilizando operações matemáticas aplicadas diretamente no ambiente do Google Earth Engine.

A utilização de variáveis topográficas em estudos de aptidão cafeeira justifica-se pela forte influência do relevo sobre o microclima agrícola, a drenagem, a disponibilidade hídrica e a distribuição térmica, fatores diretamente relacionados ao desenvolvimento do cafeeiro (Luz *et al.*, 2015; Bunn, 2015a).

As variáveis espectrais foram obtidas a partir de imagens do satélite Sentinel-2 MSI, coleção *COPERNICUS/S2_SR_HARMONIZED* nas bandas indicadas na Figura 2.2. As imagens foram filtradas espacialmente pela área de estudo utilizando a função *filterBounds()* e temporalmente entre janeiro e dezembro de 2018 por meio da função *filterDate()*. Adicionalmente, foi aplicado um filtro de cobertura de nuvens inferior a 0,01% utilizando *ee.Filter.lt()*, visando minimizar interferências atmosféricas e ruídos espectrais associados à nebulosidade (Zhu; Wang; Woodcock, 2015; Wen *et al.*, 2023).

Após a filtragem, foi gerado um compósito mediano das imagens utilizando a função *median()*, reduzindo ruídos temporais e aumentando a estabilidade espectral das imagens (Hong *et al.*, 2020), foram utilizadas bandas espectrais e índices de vegetação relacionados ao vigor vegetativo, biomassa, teor de clorofila e umidade da vegetação, Conforme Tabela 7.1.

Os índices espectrais foram calculados diretamente no ambiente do Google Earth Engine utilizando as funções *normalizedDifference()* e *expression()*, aplicadas às bandas espectrais do Sentinel-2. Esses índices são amplamente empregados em estudos agrícolas por permitirem melhor discriminação da vegetação e maior sensibilidade às condições fisiológicas das plantas Tabela 7.1 (Huete *et al.*, 2002; Pettorelli *et al.*, 2014; Gitelson; Kaufman; Merzlyak, 1996).

Após o empilhamento das variáveis ambientais utilizando a função *addBands()*, foi realizada a extração dos valores ambientais nos pontos de presença e fundo utilizando a função *sampleRegions()*, permitindo associar cada amostra aos respectivos atributos ambientais.

A seleção final das variáveis preditoras considerou simultaneamente a relevância ecológica para a cultura do café e a redução de multicolinearidade entre variáveis. A correlação entre os preditores foi avaliada por meio do coeficiente de correlação de Pearson (Dormann *et al.*, 2013; Feng *et al.*, 2019), inicialmente calculado no Google Earth Engine utilizando o redutor *ee.Reducer.pearsonsCorrelation()*.

Posteriormente, os resultados foram exportados em formato tabular utilizando a função *Export.table.toDrive()* e processados no software *R*, v4.5.1. As análises gráficas e os correlogramas foram elaborados utilizando os pacotes *ggcorrplot*, V0.1.4.1 (Kassambara; Kassambara, 2019), *ggplot2*, V4.0.2 (Wickham, 2011), *patchwork*, V1.3.2 e *tidyverse*, V2.0.0. Variáveis com coeficiente de correlação absoluto superior a 0,8 foram consideradas redundantes e removidas do conjunto final de preditores, reduzindo problemas de sobreajuste (*overfitting*) e aumentando a estabilidade estatística dos modelos (Dormann *et al.*, 2013; Merow; Smith; Silander, 2013).

4.3 Modelagem MaxEnt

A modelagem da distribuição potencial da cafeicultura foi realizada utilizando o algoritmo *MaxEnt*, implementado no Google Earth Engine por meio da função *ee.Classifier.amnhMaxent()*. O método é amplamente utilizado em modelagem de distribuição de espécies devido à sua robustez estatística, capacidade de trabalhar exclusivamente com dados de presença e bom desempenho mesmo com conjuntos de dados limitados (Phillips; Anderson; Schapire, 2006; Elith *et al.*, 2011).

Os modelos foram calibrados utilizando pontos de presença e pontos de fundo (*background points*) previamente gerados, tendo as variáveis ambientais selecionadas como preditores. Os dados amostrais foram embaralhados com a função *randomColumn()* e particionados aleatoriamente em conjuntos de treinamento e validação, utilizando as proporções de Grupo 1 (70/30), Grupo 2 (75/25) e Grupo 3 (80/20), respectivamente.

Após o treinamento, o modelo foi aplicado às variáveis ambientais por meio da função *classify()*, resultando em mapas contínuos de probabilidade de ocorrência da cafeicultura, com valores variando entre 0 e 1, representando diferentes níveis de adequabilidade ambiental.

4.4 Métricas de desempenho

O desempenho preditivo dos modelos foi avaliado por meio da curva ROC (*Receiver Operating Characteristic*) e da métrica AUC (*Area Under the Curve*), amplamente utilizadas em modelagem ambiental (Fielding; Bell, 1997; Pearce; Ferrier, 2000).

A curva ROC foi construída a partir da comparação entre os valores observados de presença e as probabilidades preditas em diferentes limiares de classificação, permitindo calcular as taxas de verdadeiros positivos (*True Positive Rate* – TPR) e falsos positivos (*False Positive Rate* – FPR). A AUC representa a capacidade do modelo em distinguir corretamente áreas de presença e ausência, sendo que valores próximos de 1 indicam elevado desempenho preditivo, enquanto valores próximos de 0,5 representam desempenho equivalente ao acaso (Swets, 1988).

Também foram calculadas métricas derivadas da matriz de confusão, incluindo acurácia, sensibilidade, especificidade e coeficiente Kappa. A sensibilidade representa a proporção de ocorrências corretamente classificadas como presença, enquanto a especificidade corresponde à proporção de ausências corretamente classificadas (Allouche; Tsoar; Kadmon, 2006).

O coeficiente Kappa foi utilizado para avaliar a concordância entre valores observados e preditos descontando os acertos esperados ao acaso (Cohen *et al.*, 2009; Landis; Koch, 1977), enquanto o índice TSS foi empregado por integrar simultaneamente sensibilidade e especificidade (Allouche; Tsoar; Kadmon, 2006).

Além da AUC, foi utilizada a taxa de omissão (*omission rate*), correspondente à proporção de ocorrências reais classificadas incorretamente como ausência (Fielding; Bell, 2007).

O limiar ótimo de classificação foi definido pelo índice de Youden, obtido a partir da maximização da diferença entre sensibilidade e taxa de falsos positivos (Pearce; Ferrier, 2000).

A importância relativa das variáveis ambientais foi avaliada pelo método *drop-one*, baseado na remoção individual de cada variável e posterior cálculo da redução da AUC do modelo, permitindo identificar a contribuição preditiva de cada variável e possíveis redundâncias entre os preditores (Elith *et al.*, 2011; Merow; Smith; Silander, 2013).

4.5 Mapas binários de presença de café

Após a calibração dos modelos, foram produzidos mapas contínuos de probabilidade de ocorrência da cafeicultura para os municípios estudados. Os mapas foram posteriormente convertidos em mapas binários utilizando o limiar definido pelo índice de Youden.

As áreas classificadas como presença de café foram estimadas utilizando a função *pixelArea* do Google Earth Engine, permitindo o cálculo da área total em hectares e quilômetros quadrados. Para minimizar possíveis superestimações associadas à resolução espacial das imagens e à mistura espectral com elementos não agrícolas, foi aplicada uma correção conservadora das áreas classificadas (Foody, 2015).

Os mapas raster foram exportados em formato GeoTIFF e a elaboração cartográfica foi realizada no *R Studio v4.5.1* utilizando os pacotes *terra* (Hijmans; Brown; Barbosa, 2026), *sf* (PeBasma *et al.*, 2018), *ggplot2* (Wickham, 2011), *viridis* (Garnier *et al.*, 2024) e *patchwork* (Pedersen, 2025).

O pacote *terra* foi utilizado para leitura, recorte e mascaramento de dados raster, enquanto o pacote *sf* foi empregado na manipulação vetorial e compatibilização dos sistemas de referência espacial. A visualização cartográfica foi realizada com o *ggplot2*, utilizando as funções *geom_raster()* e *geom_sf()*, enquanto o pacote *viridis* foi utilizado para aplicação de escalas de cores perceptualmente uniformes. O pacote *patchwork* foi empregado na composição gráfica das figuras finais.

4.6 Resultados e discussão

4.6.1 Seleção de imagens sentinel-2

A seleção das imagens Sentinel-2 foi realizada utilizando o critério de cobertura de nuvens inferior a 0,01%, visando maximizar a qualidade radiométrica dos dados empregados na modelagem ambiental. A aplicação desse limiar resultou em reduzida disponibilidade de cenas no período analisado, sendo obtida uma cena para o município de Nepomuceno e oito cenas para Patrocínio.

A diferença no número de cenas disponíveis entre os municípios está associada não apenas à elevada frequência de nebulosidade característica de regiões tropicais e subtropicais, mas

também à geometria orbital e à distribuição espacial dos tiles do Sentinel-2, fatores que influenciam a frequência e a disponibilidade de aquisições livres de nuvens em diferentes regiões (Asner, 2001; Hong *et al.*, 2020). Além disso, o percentual de cobertura de nuvens utilizado no Google Earth Engine é calculado para a cena inteira.

Apesar da redução no número de cenas disponíveis, a adoção de um limiar rigoroso teve como objetivo minimizar interferências atmosféricas, efeitos de aerossóis e ruídos espectrais capazes de comprometer a extração das variáveis ambientais e o desempenho dos modelos preditivos (Zhu; Wang; Woodcock, 2015; Wen *et al.*, 2023). Em modelagens baseadas em MaxEnt, a qualidade radiométrica dos preditores ambientais influencia diretamente a consistência das relações espaciais inferidas pelo algoritmo (Phillips; Anderson; Schapire, 2006; Elith *et al.*, 2011).


Nesse contexto, priorizou-se a qualidade espectral das cenas em detrimento da quantidade de imagens disponíveis, buscando reduzir inconsistências associadas à presença de nuvens e melhorar a representação espectral das áreas cafeeiras.

4.6.2 Seleção de preditores

A seleção dos preditores ambientais foi realizada separadamente para os grupos de variáveis bioclimáticas, espectrais e topográficas, buscando reduzir os efeitos da multicolinearidade e manter a coerência ecológica entre variáveis de mesma natureza (Dormann *et al.*, 2013; Mellow; Smith; Silander, 2013). A análise de correlação de Pearson revelou elevados níveis de correlação dentro de cada grupo de variáveis, especialmente entre índices espectrais e variáveis bioclimáticas derivadas de séries temporais semelhantes (Fick; Hijmans, 2017; Huete *et al.*, 2002).

As matrizes de correlação evidenciaram que variáveis bioclimáticas altamente correlacionadas em Patrocínio não apresentaram o mesmo comportamento em Nepomuceno, e vice-versa, demonstrando que a redundância entre preditores é fortemente influenciada pelas condições ambientais e climáticas locais. Esse resultado reforça que as relações entre variáveis ambientais variam espacialmente conforme o contexto climático, topográfico e os gradientes ambientais analisados, além de dependerem do conjunto de preditores empregados na construção dos modelos (Araújo; Guisan, 2006; Peterson; Soberón, 2012).

Figura 4.2 – Correlogramas de Pearson para os preditores no município de Nepomuceno.



Fonte: Elaborado pelo autor (2026).


Após a remoção das variáveis colineares, os conjuntos finais de preditores foram compostos por variáveis bioclimáticas, espectrais e topográficas. Para Patrocínio, foram selecionadas as variáveis bioclimáticas bio03, bio04, bio06 e bio12, enquanto para Nepomuceno permaneceram bio03, bio06, bio12, bio14 e bio15. As variáveis espectrais incluíram NDVI, AVI e GLI em Patrocínio, e NDVI, AVI e MCARI em Nepomuceno. As variáveis topográficas (elevação, declividade, orientação e sombreamento) foram mantidas em ambos os municípios Figuras 4.2 e 4.3.

Observou-se forte convergência na seleção das variáveis bioclimáticas, com destaque para aquelas associadas à temperatura e disponibilidade hídrica, diferindo apenas pela exclusão de bio15 em Patrocínio e de bio04 em Nepomuceno devido à alta colinearidade. Essa estabilidade indica o papel central dos fatores térmico-hídricos na delimitação das áreas aptas ao cultivo de café Arábica, amplamente documentado na literatura (Bunn, 2015b; Davis *et al.*, 2012). A presença recorrente dessas variáveis sugere que, mesmo em contextos espaciais distintos, os limites fisiológicos da cultura impõem restrições ambientais semelhantes.

Em contraste, os índices espectrais apresentaram maior variabilidade espacial. O GLI foi selecionado exclusivamente para Patrocínio, enquanto o MCARI foi incorporado apenas em Nepomuceno. Essa diferença reflete respostas distintas das paisagens agrícolas aos índices de vegetação, influenciadas por fatores como fenologia da cultura, vigor foliar, estrutura do dossel, práticas de manejo e condições ópticas do solo e da vegetação (Thenkabail; Lyon; Huete, 2018). O MCARI, por exemplo, é particularmente sensível à concentração de clorofila, capturando variações sutis no estado fisiológico das plantas em áreas de cultivo mais fragmentadas, como em Nepomuceno.

Esses resultados reforçam a importância de avaliações regionais específicas na seleção de variáveis espectrais e bioclimáticas, evitando generalizações que poderiam comprometer o desempenho preditivo dos modelos. Conjuntos de preditores adaptados às condições locais contribuem para modelos mais robustos e ecologicamente consistentes, especialmente em estudos de modelagem espacial aplicada à agricultura.

Figura 4.3 – Correlogramas de Pearson para os preditores no município de Patrocínio.



Fonte: Elaborado pelo autor (2026).


4.6.3 Métricas de avaliação

Os modelos apresentaram elevado desempenho discriminatório para ambos os municípios, com valores de AUC superiores a 0,80 na maioria dos cenários, indicando boa capacidade de distinção entre áreas com e sem ocorrência de café (Swets, 1988). As métricas de avaliação incluíram a Área sob a Curva ROC (AUC) e a taxa de omissão, amplamente utilizadas em modelagem de distribuição espacial (Fielding; Bell, 1997; Elith *et al.*, 2011).

Os modelos compostos por variáveis espectrais e bandas do Sentinel-2 em Nepomuceno Figura 4.4 apresentaram elevado desempenho preditivo, com valores de AUC variando entre 0,937 e 0,943 no modelo original. Após a remoção das variáveis MCARI, AVI, NDVI, B1, B4, B5, B6, B7, B8, B8A e B12 (remoção 1), os valores de AUC permaneceram praticamente estáveis, evidenciando que os preditores removidos apresentavam baixa contribuição individual para o desempenho do modelo.

Esse resultado indica que a exclusão de variáveis com contribuição nula ou reduzida pode representar uma estratégia eficiente para diminuição da complexidade e do custo computacional, sem comprometer significativamente a capacidade preditiva do modelo. Os resultados demonstram ainda que as bandas B2, B3, B11 e B12 foram suficientes para representar adequadamente os padrões espectrais associados às áreas cafeeiras em Nepomuceno.

Figura 4.4 – Gráfico de AUC para os modelos compostos por preditores espectrais em Nepomuceno.




Fonte: Elaborado pelo autor (2026).

Os modelos compostos por variáveis espectrais e bandas do Sentinel-2 em Patrocínio Figura 4.5 também apresentaram elevado desempenho preditivo, com valores de AUC variando entre 0,851 e 0,870 no modelo original. Após a remoção das variáveis AVI, NDVI, B4, B5, B8 e B12 (remoção 1), os valores de AUC reduziram para o intervalo entre 0,842 e 0,862, indicando perda de desempenho do modelo.

A redução da AUC após a remoção das variáveis sugere que parte dos preditores excluídos, embora apresentassem baixa contribuição individual, exerciam influência complementar na representação espectral das áreas cafeeiras. Esse comportamento evidencia a importância do conjunto integrado de variáveis selecionadas para capturar adequadamente as características espectrais do dossel do café em Patrocínio.

Figura 4.5 – Gráfico de AUC para os modelos compostos por preditores espectrais em Patrocínio.



Fonte: Elaborado pelo autor (2026).

De modo geral, os resultados indicam que as variáveis espectrais selecionadas apresentaram elevada capacidade discriminatória em ambos os municípios, demonstrando a eficiência

dos preditores derivados do Sentinel-2 na identificação de áreas cafeeiras. A seleção das variáveis com base na análise de correlação de Pearson e no grau de relevância dos preditores contribuiu para a construção de modelos mais robustos e ecologicamente consistentes.

Os modelos compostos por variáveis topográficas e bandas do Sentinel-2 em Nepomuceno Figura 4.6 apresentaram elevado desempenho preditivo, com valores de AUC variando entre 0,938 e 0,946 no modelo original. Após a remoção das variáveis *slope*, B7, B8 e B12 (remoção 1), observou-se aumento do desempenho, com valores de AUC entre 0,941 e 0,951, indicando que a exclusão desses preditores contribuiu para redução de redundâncias e maior eficiência discriminatória do modelo.

Entretanto, as remoções subsequentes (remoções 2 e 3) resultaram em redução dos valores de AUC, evidenciando que parte das variáveis removidas nas etapas posteriores possuía contribuição relevante para a representação ambiental das áreas cafeeiras. Esse comportamento demonstra que, embora a simplificação do conjunto de preditores possa melhorar o desempenho inicial do modelo, remoções excessivas tendem a comprometer sua capacidade preditiva.


De modo geral, os modelos topográficos apresentaram os maiores desempenhos em Nepomuceno, com AUC variando entre 0,938 e 0,951. Esses resultados evidenciam a forte influência do relevo sobre a distribuição espacial da cafeicultura em regiões montanhosas, onde fatores como altitude, declividade e orientação das vertentes influenciam diretamente condições microclimáticas associadas à temperatura, drenagem e disponibilidade de radiação solar (??).

Em Patrocínio, os modelos compostos por variáveis topográficas Figura 4.7 apresentaram desempenho moderado a elevado, com valores de AUC variando entre 0,825 e 0,865 no modelo original. Diferentemente do observado em Nepomuceno, a remoção de variáveis resultou em redução do desempenho preditivo, indicando maior dependência do conjunto completo de preditores topográficos para representação da distribuição espacial da cafeicultura no município.

Esse resultado sugere que, em Patrocínio, as variáveis topográficas exercem influência complementar na modelagem ambiental, contribuindo conjuntamente para a discriminação das áreas cafeeiras.

Os modelos compostos por variáveis bioclimáticas em Nepomuceno Figura 4.8 apresentaram elevado desempenho preditivo, com valores de AUC variando entre 0,936 e 0,945 no modelo original. Após a remoção das variáveis bio03, bio14, B1, B8, B8A, B9 e B12 (remoção

Figura 4.6 – Gráfico de AUC para os modelos compostos por preditores topográficos em Nepomuceno.




Fonte: Elaborado pelo autor (2026).

1), observou-se manutenção dos valores máximos de AUC, embora com ampliação do intervalo para 0,926 a 0,945.

Esse comportamento indica que parte das variáveis removidas apresentava baixa contribuição individual para o desempenho global do modelo, permitindo simplificação parcial do conjunto de preditores sem perdas substanciais na capacidade discriminatória. Entretanto, a remoção adicional de variáveis na etapa seguinte (remoção 2) resultou em redução dos valores de AUC, evidenciando perda de informação ambiental relevante para a modelagem da distribuição espacial da cafeicultura.

Os modelos bioclimáticos para Patrocínio Figura 4.9 apresentaram valores de AUC variando entre 0,801 e 0,863 no modelo original. Diferentemente do observado em Nepomuceno,

Figura 4.7 – Gráfico de AUC para os modelos compostos por preditores topográficos em Patrocínio.



Fonte: Elaborado pelo autor (2026).


a remoção de variáveis resultou em redução do desempenho preditivo já na primeira etapa de remoção, indicando maior dependência do conjunto completo de variáveis bioclimáticas para representação da distribuição espacial da cafeicultura no município.

Apesar da redução da AUC após a remoção dos preditores, os modelos mantiveram estabilidade moderada, evidenciando a forte influência dos gradientes climáticos sobre a aptidão ambiental do café Arábica. Esse comportamento reforça a importância de variáveis associadas à temperatura e disponibilidade hídrica na delimitação das áreas potencialmente aptas ao cultivo.

Os modelos compostos pela integração de variáveis espectrais, bioclimáticas e topográficas em Nepomuceno (Figura 4.10) apresentaram elevado desempenho preditivo, com valores de AUC variando entre 0,925 e 0,934 no modelo original. Após a remoção das variáveis elevation, aspect, bio03, bio12, bio15, B1, B3, B4, B5, B6, B7, B8 e B12, observou-se aumento do desempenho do modelo, com valores de AUC entre 0,935 e 0,938.

Esse resultado sugere a presença de redundâncias entre os preditores originalmente utilizados, indicando que a simplificação do conjunto de variáveis contribuiu para redução da

Figura 4.8 – Gráfico de AUC para os modelos compostos por preditores bioclimáticos em Nepomuceno.




Fonte: Elaborado pelo autor (2026).

colinearidade e maior eficiência discriminatória do modelo. A melhora do desempenho após a remoção de variáveis reforça que modelos mais parcimoniosos podem apresentar maior robustez preditiva quando compostos apenas por preditores ambientalmente relevantes.

Para Patrocínio, os modelos compostos por variáveis bioclimáticas, topográficas e espectrais Figura 4.11 apresentaram valores de AUC variando entre 0,851 e 0,870 no modelo original. Diferentemente do observado em Nepomuceno, a remoção de variáveis resultou em redução do desempenho preditivo, evidenciando que o conjunto original de preditores apresentava maior complementaridade ambiental.

A diminuição dos valores de AUC após as remoções sugere que variáveis aparentemente redundantes ainda exerciam contribuição conjunta importante para a representação das condições ambientais associadas à cafeicultura em Patrocínio. Esse comportamento demonstra que a resposta dos modelos à simplificação dos preditores pode variar conforme as características ambientais e espaciais de cada município.

Figura 4.9 – Gráfico de AUC para os modelos compostos por preditores bioclimáticos em Patrocínio.




Fonte: Elaborado pelo autor (2026).

A validação dos modelos com diferentes preditores, permitiu evidenciar que o auc depende do tipo de preditores, partição de dados e varia sempre que são mexidas as variáveis predictoras, pois o modelo recalcula. Para Nepomuceno foi possível concluir que o modelo com variáveis de altitude apresentou melhor desempenho, seguido do modelo com variáveis climáticas e para Patrocínio foi possível constatar que o modelo com todas as variáveis esteve melhor seguido do modelo com variáveis bioclimáticas, evidenciando que o processo de modelagem deve ser ajustado localmente.

A avaliação dos modelos utilizando diferentes conjuntos de preditores permitiu evidenciar que o desempenho preditivo, representado pelos valores de AUC, depende diretamente do tipo de variável empregada, da estratégia de particionamento dos dados e da composição final dos preditores utilizados no modelo. Observou-se que pequenas modificações no conjunto de variáveis resultaram em alterações nos valores de AUC, refletindo o caráter iterativo do algoritmo MaxEnt, que recalibra continuamente as relações entre os registros de ocorrência e o espaço ambiental disponível a cada nova configuração de entrada.

Para Nepomuceno, os modelos compostos por variáveis topográficas apresentaram os maiores desempenhos preditivos, seguidos pelos modelos bioclimáticos, evidenciando a forte influência do relevo e das condições climáticas locais sobre a distribuição espacial da cafeicultura no município. Possivelmente, esse comportamento esteja associado à elevada heterogenei-

Figura 4.10 – Gráfico de AUC para os modelos compostos por variáveis espectrais, bioclimáticas e topográficas em Nepomuceno.



Fonte: Elaborado pelo autor (2026).

dade ambiental da região, caracterizada por relevo montanhoso, grande variabilidade altitudinal e presença de gradientes microclimáticos mais acentuados, típicos das áreas do sul de Minas Gerais associadas aos mares de morros e à influência da Serra da Mantiqueira.


A maior complexidade topográfica de Nepomuceno favorece diferenças locais de temperatura, disponibilidade hídrica, drenagem e incidência de radiação solar, aumentando a capacidade discriminatória das variáveis altimétricas e topográficas na delimitação das áreas aptas ao cultivo do café.

Já em Patrocínio, os melhores resultados foram obtidos pelos modelos integrando variáveis espectrais, bioclimáticas e topográficas, seguidos pelos modelos compostos exclusivamente por variáveis bioclimáticas. Esse comportamento pode estar relacionado à maior homogeneidade geomorfológica e climática do município, localizado na região do Cerrado Mineiro, onde predominam superfícies mais suavizadas e extensos platôs agrícolas. Nessas condições, variáveis espectrais associadas à resposta do dossel vegetativo e variáveis climáticas relacionadas à disponibilidade hídrica e térmica tendem a exercer maior influência conjunta sobre a distribuição espacial da cafeicultura.

Os resultados demonstram, portanto, que a importância relativa dos preditores ambientais varia espacialmente conforme as características climáticas, topográficas e estruturais das paisagens agrícolas analisadas, evidenciando que o processo de modelagem ambiental deve ser ajustado de forma específica para cada região de estudo.

De forma geral, os modelos integrando variáveis espectrais, topográficas e bioclimáticas apresentaram os maiores desempenhos globais, reforçando que a integração de múltiplas

Figura 4.11 – Gráfico do AUC para os modelos compostos por variáveis espectrais, bioclimáticas e topográficas em Patrocínio.



Fonte: Elaborado pelo autor (2026).

dimensões ambientais favorece maior robustez preditiva (Elith *et al.*, 2011). A combinação de variáveis associadas ao relevo, clima e resposta espectral da vegetação permite representar de maneira mais consistente os múltiplos fatores ambientais que condicionam a distribuição espacial da cafeicultura.

Além disso, verificou-se que a remoção de variáveis com contribuição próxima de zero frequentemente não reduziu significativamente o desempenho dos modelos, indicando elevada redundância entre alguns preditores ambientais (Dormann *et al.*, 2013). Esse comportamento sugere que modelos mais parcimoniosos podem manter elevada capacidade preditiva mesmo utilizando conjuntos reduzidos de variáveis, contribuindo para diminuição da complexidade computacional, redução dos efeitos da multicolinearidade e maior interpretabilidade ecológica dos modelos finais.

4.6.4 Métricas de validação

A validação dos modelos foi realizada por meio das métricas Acurácia, Sensibilidade, Especificidade e coeficiente Kappa, amplamente utilizadas em modelos de classificação binária e distribuição espacial (Fielding; Bell, 1997; Allouche; Tsoar; Kadmon, 2006). Essas métricas permitem avaliar diferentes dimensões do desempenho preditivo, fornecendo interpretação mais robusta da capacidade discriminatória e da consistência dos modelos.

Em Nepomuceno, os modelos altimétricos associados às bandas do Sentinel-2 apresentaram os melhores resultados de validação (Tabela 4.1), especialmente no fluxo “Removal_1”, com Acurácia de 0,904 e coeficiente Kappa de 0,809. Esses resultados indicam elevada concordância entre valores observados e previstos (Landis; Koch, 1977), evidenciando a forte influência do relevo na delimitação espacial da cafeicultura em regiões montanhosas. A melhora no desempenho após a remoção de variáveis sugere ainda que a exclusão de preditores redundantes contribuiu para maior eficiência discriminatória e redução de possíveis efeitos de colinearidade.

Tabela 4.1 – Métricas de validação dos modelos aplicados ao município de Nepomuceno.

Preditores	Fluxo	Acurácia	Sensibilidade	Especificidade	Kappa
Altimétricos	Original	0,899	0,879	0,920	0,799
	Removal_1	0,904	0,941	0,868	0,809
	Removal_2	0,824	0,850	0,800	0,649
	Removal_3	0,886	0,856	0,917	0,772
Bioclimáticos	Original	0,884	0,845	0,921	0,767
	Removal_1	0,897	0,865	0,928	0,793
Espectrais	Original	0,897	0,885	0,909	0,793
	Removal_1	0,824	0,850	0,6800	0,649
Todos os Preditores	Original	0,870	0,859	0,881	0,740
	Removal_1	0,879	0,863	0,895	0,758

Fonte: Elaborado pelo autor (2026).

Os modelos bioclimáticos também apresentaram elevado desempenho e maior estabilidade após a remoção de variáveis redundantes, sugerindo que a simplificação dos modelos favoreceu maior capacidade de generalização espacial (Merow; Smith; Silander, 2013). Em contraste, os modelos espectrais demonstraram maior sensibilidade à remoção de variáveis,

indicando forte dependência das bandas relacionadas ao infravermelho próximo e às regiões *red-edge*, fundamentais na discriminação do vigor vegetativo, biomassa foliar e estrutura do dossel cafeeiro.

Em Patrocínio, os modelos bioclimáticos apresentaram os melhores resultados globais (Tabela 4.2), com Acurácia de até 0,809 e coeficiente Kappa de 0,618, evidenciando maior influência dos gradientes climáticos regionais sobre a distribuição espacial da cafeicultura. Os modelos integrados apresentaram elevada sensibilidade, porém com redução da especificidade, indicando maior capacidade de identificar áreas de presença da cultura em detrimento da correta exclusão de áreas sem ocorrência. Esse comportamento sugere tendência ao sobreajuste, característica frequentemente associada a modelos MaxEnt excessivamente complexos. De forma

Tabela 4.2 – Métricas de validação dos modelos aplicados ao município de Patrocínio.

Preditores	Fluxo	Acurácia	Sensibilidade	Especificidade	Kappa
Altimétricos	Original	0,808	0,824	0,793	0,616
	Removal_1	0,763	0,766	0,760	0,526
	Removal_2	0,777	0,770	0,784	0,553
Bioclimáticos	Original	0,801	0,832	0,768	0,601
	Removal_1	0,809	0,815	0,803	0,618
	Removal_2	0,796	0,754	0,841	0,592
Espectrais	Original	0,753	0,746	0,760	0,506
	Removal_1	0,776	0,796	0,757	0,553
	Removal_2	0,724	0,684	0,764	0,448
	Removal_3	0,779	0,801	0,757	0,558
	Removal_4	0,780	0,795	0,765	0,560
Todos os Preditores	Original	0,787	0,855	0,715	0,572
	Removal_1	0,796	0,807	0,785	0,492
	Removal_2	0,772	0,871	0,669	0,542
	Removal_3	0,695	0,923	0,456	0,383

Fonte: Elaborado pelo autor (2026).

geral, os resultados demonstram que a remoção criteriosa de variáveis redundantes favoreceu modelos mais parcimoniosos sem perdas substanciais de desempenho, reforçando que a eficiência do MaxEnt está mais associada à relevância ecológica dos preditores do que à quantidade

de variáveis utilizadas (Dormann *et al.*, 2013). Em alguns casos, a simplificação do conjunto de variáveis promoveu inclusive melhorias nos indicadores de validação, sugerindo redução de redundâncias ambientais e maior capacidade de generalização espacial.

A análise integrada das métricas de validação evidencia ainda a importância da utilização de múltiplos critérios de avaliação em modelagens ambientais. Embora métricas como Acurácia possam superestimar o desempenho em conjuntos de dados desbalanceados, métricas como Sensibilidade, Especificidade e coeficiente Kappa permitem interpretar de forma mais detalhada a capacidade do modelo em discriminar corretamente áreas de presença e ausência da cultura. Dessa forma, a combinação dessas métricas possibilita avaliação mais consistente da robustez, estabilidade e capacidade de generalização espacial dos modelos preditivos.

4.6.5 Mapas binários de presença de café

Os mapas de probabilidade de ocorrência do café foram elaborados a partir dos modelos com melhor desempenho estatístico, considerando simultaneamente AUC, Acurácia, Sensibilidade, Especificidade e coeficiente Kappa (Fielding; Bell, 1997; Allouche; Tsoar; Kadmon, 2006; Elith *et al.*, 2011). Embora a AUC seja amplamente utilizada para avaliar capacidade discriminatória, sua interpretação isolada pode favorecer modelos superajustados (Merow; Smith; Silander, 2013). Assim, a seleção final priorizou modelos com maior equilíbrio entre sensibilidade e especificidade.

Para Nepomuceno, o modelo altimétrico “Removal_1” foi selecionado como modelo final, apresentando maior coeficiente Kappa e melhor equilíbrio entre identificação de áreas favoráveis e exclusão de áreas sem ocorrência de café. Esse resultado reforça a forte influência do relevo sobre a distribuição espacial da cultura no sul de Minas Gerais(?).


Para Patrocínio, o modelo bioclimático “Removal_1” apresentou maior estabilidade preditiva e melhor capacidade de generalização espacial, indicando maior influência das condições térmicas e pluviométricas do Cerrado Mineiro sobre a adequabilidade ambiental do café.

A partir do mapa binário derivado do modelo selecionado, estimou-se uma área total de 18.297,15 ha classificados como cultivo de café em Nepomuceno. Considerando possíveis superestimações associadas à mistura espectral e inclusão de feições lineares, foi aplicada uma correção conservadora de 20%, resultando em área estimada de 14.637,57 ha. Comparando-se esse valor aos dados de referência fornecidos para modelagem do Café (13.822,85 ha), observou-se

diferença relativa de aproximadamente 5,9%, considerada baixa para estudos de mapeamento agrícola em escala municipal (Foody, 2015; Pimentel-Gomes, 2000).


Os resultados demonstram elevada coerência espacial entre o modelo gerado e os dados de referência, reforçando o potencial da integração entre MaxEnt e sensoriamento remoto para aplicações em monitoramento agrícola e planejamento territorial.

Figura 4.12 – Mapa de distribuição espacial do café no município de Nepomuceno em 2018, obtido a partir do modelo MaxEnt.



Fonte: Elaborado pelo autor (2026).

Figura 4.13 – Mapa de distribuição espacial do café no município de Patrocínio em 2018, obtido a partir do modelo MaxEnt.



Fonte: Elaborado pelo autor (2026).

5 ARTIGO 3 – INTEGRAÇÃO MULTISSENSOR E MULTITEMPORAL PARA MAPEAMENTO DE LAVOURAS DE CAFÉ USANDO A TÉCNICA MAXENT

5.1 Materiais e métodos

O presente capítulo teve como objetivo avaliar o desempenho da integração multissensor no mapeamento de lavouras de café arábica nos municípios de Nepomuceno e Patrocínio, Minas Gerais, utilizando o algoritmo MaxEnt.

A modelagem foi conduzida utilizando imagens orbitais referentes ao período entre janeiro e dezembro de 2018, provenientes dos sensores Sentinel-2 MSI, Landsat 8 OLI/TIRS e MODIS MOD13Q1. Todo o processamento foi realizado no ambiente do GEE (Gorelick *et al.*, 2017).

Os preditores ambientais utilizados nesta etapa corresponderam exclusivamente às variáveis que apresentaram melhor desempenho estatístico no capítulo anterior. Para o município de Patrocínio foram utilizadas variáveis bioclimáticas ('bio01', 'bio12', 'bio03', 'bio04', 'bio15'), enquanto em Nepomuceno foram empregados preditores topográficos derivados do modelo altimétrico (Aspect, hillshade, elevation) previamente selecionado.

As imagens Landsat 8 foram obtidas da coleção LANDSAT/LC08/C02/T1L2. Inicialmente, a coleção foi filtrada espacialmente utilizando os limites municipais e temporalmente para o ano de 2018. Posteriormente, foi aplicado mascaramento de nuvens e sombras por meio da banda *QAPIXEL*, removendo pixels classificados como nuvens, sombras, cirrus e pixels inválidos. Também foi aplicada a máscara de saturação radiométrica utilizando a banda *QARAD-SAT*. Após a remoção dos pixels contaminados, as bandas espectrais foram convertidas para reflectância de superfície utilizando os fatores de escala da coleção Landsat Collection 2 Level 2. Em seguida, foi gerado um compósito temporal mediano para reduzir ruídos atmosféricos e minimizar variações espectrais ocasionadas por observações isoladas.

As bandas Landsat 8 utilizadas na modelagem incluíram as regiões espectrais do azul, verde, vermelho, infravermelho próximo (NIR), infravermelho de ondas curtas (SWIR) e infravermelho termal (LWIR). Além das bandas espectrais, foram calculados os índices NDVI, AVI e MCARI.

As imagens MODIS foram obtidas da coleção *MODIS/061/MOD13Q1*, composta por produtos de vegetação com resolução espacial de 250 m. Após a filtragem temporal e espa-

cial, foi gerado um compósito mediano anual. Foram utilizadas as bandas de reflectância do vermelho, azul, infravermelho próximo e SWIR, além dos índices NDVI e EVI já disponibilizados pelo produto MOD13Q1. Também foram calculados os índices AVI e MCARI a partir das bandas espectrais do sensor.

As imagens Sentinel-2 foram obtidas da coleção *COPERNICUS/S2SRHARMONIZED*. O processamento incluiu filtragem temporal, remoção de nuvens e geração de compósitos medianos anuais. Foram utilizadas bandas espectrais do visível, NIR e SWIR, bem como índices espectrais derivados da vegetação.

Todas as fases de preparação, assim como de modelagem, aconteceram observando os preceitos levados a cabo na análise dos preditores no capítulo 2.

5.2 Resultados e discussão

5.2.1 Seleção de imagens

Sob os mesmos critérios de filtragem por cobertura de nuvens (<10%) e utilizando o sensor Sentinel-2, foram obtidas 67 imagens para o município de Patrocínio e 11 imagens para Nepomuceno. Para o sensor MODIS, foram obtidas 23 imagens em cada município. Já para o satélite Landsat, foram disponibilizadas 63 imagens para Patrocínio, respectivamente, e 19 imagens para Nepomuceno.

Essas diferenças no número de cenas entre os municípios são esperadas e podem ser explicadas principalmente pela extensão territorial distinta das duas áreas de estudo. Conforme dados oficiais do IBGE, Patrocínio possui uma área de 2.891,175 km², enquanto Nepomuceno tem 582,533 km², ou seja, Patrocínio é aproximadamente cinco vezes maior (Instituto Brasileiro de Geografia e Estatística (IBGE), 2022). Em sensoriamento remoto, áreas de maior extensão territorial têm maior probabilidade de serem capturadas em diferentes órbitas e datas de aquisição, especialmente em sistemas de varredura orbital que cobrem faixas geográficas fixas a cada passagem.

Outro fator importante é a resolução temporal (revisita) dos sensores. O Sentinel-2 tem um período de revisita nominal de 5 dias (com dois satélites em constelação), significativamente mais frequente que os 16 dias tradicionais dos sensores Landsat 8, o que geralmente resulta em

maior disponibilidade de imagens livres de nuvens ao longo do tempo (Drusch *et al.*, 2012; Thenkabail; Lyon; Huete, 2018).

Sensores como MODIS, embora possuam alta cobertura temporal (diária em muitos produtos), apresentam resolução espacial mais baixa, o que limita sua utilidade para mapeamentos detalhados em escala municipal, mas ainda assim são valiosos para séries temporais e análise da variabilidade fenológica. A similaridade no número de imagens MODIS entre os municípios reflete mais a continuidade temporal do sensor do que diferenças espaciais, já que a resolução espacial bruta não depende diretamente da área de interesse.


Portanto, a combinação de fatores — extensão territorial, configuração da constelação de satélites, período de revisita e resoluções espacial e temporal dos sensores — explica as diferenças observadas no número de cenas disponíveis para Patrocínio e Nepomuceno. Esses aspectos são fundamentais para o planejamento do uso de dados de sensoriamento remoto em modelagem ambiental e agrícola, influenciando diretamente a quantidade de observações utilizáveis ao longo do tempo.

5.2.2 Métricas de avaliação

A avaliação do desempenho dos modelos *MaxEnt* para os diferentes sensores orbitais foi realizada utilizando principalmente a métrica AUC (*Area Under the Curve*), amplamente empregada em modelos de distribuição espacial por representar a capacidade discriminatória do modelo entre áreas de presença e ausência (Swets, 1988; Phillips; Anderson; Schapire, 2006). De modo geral, os resultados demonstraram que o desempenho dos modelos variou em função da resolução espacial do sensor, do conjunto de variáveis ambientais utilizadas e das características ambientais específicas de cada município.

No município de Nepomuceno, os modelos utilizando variáveis altimétricas associadas às bandas do Sentinel-2 apresentaram elevado desempenho preditivo, com valores de AUC variando entre 0,925 e 0,934 no modelo original. Esse modelo foi composto pelas variáveis topográficas *elevation*, *aspect* e *hillshade*, além das bandas *B1*, *B2*, *B3*, *B4*, *B5*, *B6*, *B8A*, *B9* e *B11*. A remoção de variáveis redundantes promoveu melhorias no desempenho, sendo observados valores de AUC entre 0,935 e 0,938 no modelo *Remoção 1*, composto pelas variáveis *elevation*, *hillshade*, *B4*, *B5*, *B8A* e *B12*. Esse resultado sugere a existência de redundância entre alguns preditores no modelo original, cuja exclusão favoreceu maior eficiência preditiva.

Figura 5.1 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do Sentinel-2 em Nepomuceno.




Fonte: Elaborado pelo autor (2026).

Valores de AUC superiores a 0,90 indicam excelente capacidade discriminatória do modelo, demonstrando elevada aptidão em capturar a heterogeneidade espectral e topográfica da paisagem cafeeira de Nepomuceno. As bandas *red-edge* e SWIR do Sentinel-2 apresentaram elevada relevância devido à sua capacidade de detectar variações estruturais e fisiológicas da vegetação, especialmente relacionadas ao vigor vegetativo e ao teor de água nas plantas (Drusch *et al.*, 2012; Wang; Li; Zhang, 2020; Xie; Sun; Li, 2019).

Para o município de Patrocínio, o mesmo conjunto de preditores apresentou desempenho inferior, com valores de AUC variando entre 0,866 e 0,901 no modelo original, evidenciando maior variabilidade entre as partições de treinamento e teste. Esse comportamento sugere maior influência do processo de particionamento dos dados sobre o desempenho do modelo. No modelo *Remoção 1*, os valores de AUC apresentaram menor amplitude, variando entre 0,842 e 0,858, sendo o conjunto composto pelas variáveis *BIO06*, *B1*, *B3*, *B4*, *B9* e *B11*. Esses resultados ressaltam a importância das variáveis bioclimáticas e das bandas do visível e infravermelho próximo na representação espectral do dossel cafeeiro em regiões de relevo menos acidentado.

Em ambos os municípios, observou-se a recorrência de determinadas bandas espectrais nos modelos finais, evidenciando sua relevância na discriminação das áreas de cultivo de café.

Figura 5.2 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do Sentinel-2 em Patrocínio.




Fonte: Elaborado pelo autor (2026).

Os modelos desenvolvidos para Nepomuceno utilizando bandas espectrais do Landsat-8 integradas às variáveis altimétricas também apresentaram elevado desempenho, com valores de AUC variando entre 0,839 e 0,843. O conjunto de variáveis incluiu *elevation*, *aspect*, *hillshade* e as bandas *coastal*, *blue*, *green*, *red*, *nir*, *swir1*, *swir2* e *lwir1*. Nenhum dos preditores apresentou contribuição nula ao modelo, evidenciando que todas as variáveis desempenharam papel relevante na construção da superfície de probabilidade gerada pelo MaxEnt. As bandas do infravermelho próximo e do SWIR mostraram-se particularmente importantes na discriminação de padrões de umidade e biomassa vegetal (Pettorelli *et al.*, 2014). Além disso, a integração das variáveis topográficas permitiu melhor representação dos efeitos do relevo sobre o desenvolvimento da cafeicultura em áreas montanhosas (Thioune *et al.*, 2020).

Em Patrocínio, os modelos com Landsat-8 apresentaram valores de AUC variando entre 0,839 e 0,841 no modelo original. A remoção de variáveis promoveu discreta melhora no

desempenho, com AUC entre 0,824 e 0,846 no modelo *Remoção 1*, composto pelas variáveis *BIO03*, *BIO01*, *blue* e *lwir1*. Apesar da melhoria observada, verificou-se elevada amplitude entre os valores das partições, evidenciando a influência do processo de amostragem sobre a estabilidade do modelo. Esse comportamento sugere possível redundância entre alguns preditores ambientais e espectrais (Allouche; Tsoar; Kadmon, 2006). Ainda assim, as bandas termais e do visível apresentaram contribuição relevante na representação das condições microclimáticas e da resposta espectral das lavouras cafeeiras.

Figura 5.3 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do Landsat-8 em Nepomuceno.



Fonte: Elaborado pelo autor (2026).

Os modelos de Nepomuceno utilizando variáveis altimétricas associadas às bandas do sensor MODIS apresentaram desempenho inferior quando comparados ao Sentinel-2 e Landsat-8. O modelo original, composto pelas variáveis *elevation*, *hillshade*, *aspect*, *RED*, *NIR*, *BLUE* e *SWIR*, apresentou valores de AUC variando entre 0,837 e 0,861, sendo o maior valor observado na terceira partição. Nos modelos *Remoção 1* e *Remoção 2*, os valores de AUC mantiveram comportamento semelhante ao observado no modelo original, indicando que a exclusão de variáveis não resultou em ganhos substanciais de desempenho.

Para o município de Patrocínio, os modelos utilizando bandas espectrais do sensor MODIS integradas às variáveis bioclimáticas apresentaram desempenho moderado. O modelo original, composto pelas variáveis *BIO01*, *BIO03*, *BIO04*, *BIO12*, *BIO15* e pelas bandas espectrais *RED*, *NIR*, *BLUE* e *SWIR*, apresentou valores de AUC variando entre 0,740 e 0,753. Após a





Figura 5.4 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do Landsat-8 em Patrocínio.

Fonte: Elaborado pelo autor (2026).

remoção de variáveis no modelo *Remoção 1*, observou-se aumento do desempenho, com AUC variando entre 0,773 e 0,781. Esse comportamento sugere a presença de variáveis redundantes no modelo original, cuja exclusão reduziu ruídos e favoreceu maior capacidade preditiva do MaxEnt (Merow; Smith; Silander, 2013; Elith *et al.*, 2011). Apesar da melhoria observada, os valores permaneceram inferiores aos obtidos com sensores de maior resolução espacial, evidenciando as limitações do MODIS na representação de paisagens agrícolas heterogêneas (Pettorelli *et al.*, 2014).

De maneira geral, os resultados evidenciaram diferenças significativas entre os municípios e entre os sensores avaliados. Em Nepomuceno, a integração entre variáveis topográficas e bandas espectrais apresentou elevada eficiência, especialmente com Sentinel-2 e Landsat-8, indicando forte influência do relevo e da heterogeneidade espectral local sobre a distribuição da cafeicultura. Em Patrocínio, as variáveis bioclimáticas apresentaram maior relevância, refletindo a influência das condições climáticas regionais sobre a aptidão agrícola do café arábica. Além disso, sensores de maior resolução espacial apresentaram melhor desempenho devido à

Figura 5.5 – Gráfico de AUC para os modelos compostos por variáveis altimétricas e bandas do sensor MODIS em Nepomuceno.




Fonte:

Elaborado pelo autor (2026).

redução do efeito de mistura espectral e à maior capacidade de representar pequenas propriedades agrícolas e paisagens heterogêneas (Pettorelli *et al.*, 2014; Nagendra, 2001).

As diferenças observadas no desempenho dos modelos entre os sensores orbitais estão diretamente relacionadas às características espaciais, espectrais e temporais de cada sistema sensor. O Sentinel-2 apresentou os melhores resultados devido à sua alta resolução espacial (10–20 m) e à presença de bandas *red-edge*, altamente sensíveis às variações fisiológicas e estruturais da vegetação (Drusch *et al.*, 2012). Essas bandas permitem maior capacidade de discriminação entre áreas cafeeiras e outras coberturas vegetais, especialmente em regiões de agricultura fragmentada e relevo complexo, como Nepomuceno.

Figura 5.6 – Gráfico de AUC para os modelos compostos por variáveis bioclimáticas e bandas do sensor MODIS em Patrocínio.



Fonte: Elaborado pelo autor (2026).

O Landsat-8, apesar de possuir resolução espacial inferior ao Sentinel-2 (30 m), também apresentou desempenho elevado devido à estabilidade radiométrica do sensor e à presença de bandas no infravermelho próximo, SWIR e termal, importantes para detectar padrões relacionados à umidade, biomassa vegetal e temperatura da superfície (Pettorelli *et al.*, 2014). Entretanto, sua menor resolução espacial aumenta parcialmente o efeito de mistura espectral, reduzindo a capacidade de representar pequenas áreas agrícolas quando comparado ao Sentinel-2.

Por outro lado, os modelos gerados com o MODIS apresentaram os menores valores de AUC, principalmente em função de sua resolução espacial mais grosseira (250 m). Em paisagens heterogêneas, como áreas cafeeiras associadas a fragmentos florestais, pastagens e pequenas propriedades rurais, um único pixel MODIS frequentemente representa diferentes tipos de cobertura do solo simultaneamente, fenômeno conhecido como mistura espectral (Nagendra, 2001). Essa limitação reduz a capacidade do modelo em discriminar adequadamente as áreas de cultivo de café. Apesar disso, o MODIS apresenta elevada resolução temporal, permitindo

maior frequência de aquisição de imagens e estabilidade temporal dos índices de vegetação, característica relevante em análises multitemporais (Huete *et al.*, 2002).

Além das diferenças entre sensores, os resultados demonstraram que a resposta dos modelos também depende das características ambientais locais. Em Nepomuceno, a forte influência do relevo favoreceu modelos baseados em variáveis altimétricas e sensores de maior detalhamento espacial. Em Patrocínio, as variáveis bioclimáticas apresentaram maior contribuição, indicando maior influência das condições climáticas regionais sobre a distribuição espacial da cafeicultura. Esses resultados reforçam que a escolha do sensor e do conjunto de preditores deve considerar simultaneamente a escala espacial da análise, a heterogeneidade da paisagem e as características ambientais da área de estudo (Elith *et al.*, 2011; Merow; Smith; Silander, 2013).

5.3 Métricas de validação

A avaliação do desempenho dos modelos MaxEnt para os diferentes sensores orbitais em Nepomuceno evidenciou diferenças expressivas entre os conjuntos de dados empregados e entre as etapas de remoção de variáveis, considerando as métricas de (acurácia), (sensibilidade), (especificidade) e coeficiente Kappa (Tabela 5.1). Essas métricas permitem avaliar não apenas a capacidade global de acerto dos modelos, mas também sua eficiência em discriminar corretamente áreas de presença e ausência da cafeicultura, fornecendo interpretação mais robusta do desempenho preditivo (Fielding; Bell, 1997; Allouche; Tsoar; Kadmon, 2006).

Tabela 5.1 – Métricas de validação dos modelos baseados em diferentes sensores orbitais para o município de Nepomuceno.

Satélite	Etapas	Acurácia	Sensibilidade	Especificidade	Kappa
Sentinel-2	Original	0,896	0,909	0,882	0,791
	Removal_1	0,884	0,856	0,911	0,767
	Removal_2	0,877	0,872	0,882	0,754
Landsat-8	Original	0,871	0,869	0,872	0,741
MODIS	Original	0,742	0,636	0,848	0,484
	Removal_1	0,771	0,684	0,858	0,542
	Removal_2	0,765	0,715	0,815	0,530

Fonte: Elaborado pelo autor (2026).

Para o município de Nepomuceno, os modelos desenvolvidos a partir dos dados do Sentinel-2 apresentaram os melhores desempenhos globais de validação. O modelo original obteve Acurácia de 0,896, Sensitivity de 0,909, Specificity de 0,882 e coeficiente Kappa de 0,791, indicando elevada capacidade de discriminar corretamente áreas cafeeiras e não cafeeiras. Os elevados valores de sensibilidade demonstram que o modelo apresentou grande eficiência em identificar corretamente áreas de ocorrência do cultivo, enquanto os valores de especificidade indicam adequado desempenho na exclusão de áreas sem presença de café.

Após o processo de simplificação do modelo, verificou-se que a Remoção 1 promoveu pequena redução na acurácia global (0,884) e no coeficiente Kappa (0,767), porém apresentou aumento da especificidade (0,911), indicando maior eficiência na identificação correta das áreas sem ocorrência da cultura. Esse comportamento sugere que a exclusão de determinadas variáveis favoreceu um modelo mais conservador, reduzindo falsos positivos. Já a Remoção 2 apresentou Acurácia de 0,877, Sensibilidade de 0,872, Especificidade de 0,882 e Kappa de 0,754, demonstrando leve perda de desempenho em relação ao modelo original, embora mantendo valores elevados de validação. Esses resultados evidenciam que, mesmo com a redução do conjunto de variáveis, os modelos baseados em Sentinel-2 mantiveram elevada robustez preditiva, reforçando a importância da alta resolução espacial e espectral do sensor para representar a heterogeneidade da paisagem cafeeira em Nepomuceno.

Os modelos construídos com dados do Landsat-8 apresentaram desempenho intermediário, com Acurácia de 0,871, Sensibilidade de 0,869, Especificidade de 0,872 e coeficiente Kappa de 0,741 no modelo original. Embora os resultados sejam considerados satisfatórios, observou-se desempenho ligeiramente inferior em comparação ao Sentinel-2, provavelmente em função da menor resolução espacial do Landsat-8 (30 m), que aumenta parcialmente o efeito de mistura espectral em paisagens agrícolas fragmentadas. Ainda assim, os valores obtidos indicam adequada capacidade do sensor em representar padrões ambientais relacionados à cafeicultura, especialmente quando integrado a variáveis topográficas.

Por outro lado, os modelos desenvolvidos com dados do MODIS apresentaram os menores desempenhos entre os sensores avaliados. O modelo original apresentou Acurácia de 0,742, Sensibilidade de 0,636, Especificidade de 0,848 e coeficiente Kappa de 0,484, evidenciando menor concordância entre valores observados e previstos. Os baixos valores de sensibilidade indicam menor capacidade do modelo em identificar corretamente áreas cafeeiras, sugerindo subestimação das áreas de ocorrência da cultura.

Apesar disso, a simplificação do modelo promoveu melhorias relevantes no desempenho do MODIS. Na Remoção 1, observou-se aumento da acurácia para 0,771, da sensibilidade para 0,684, da especificidade para 0,858 e do coeficiente Kappa para 0,542, representando o melhor desempenho entre os fluxos desse sensor. A Remoção 2 manteve comportamento semelhante, apresentando Acurácia de 0,765, Sensibilidade de 0,715, Especificidade de 0,815 e Kappa de 0,530. Esses resultados sugerem que a remoção de variáveis redundantes reduziu ruídos e favoreceu maior estabilidade preditiva do modelo, embora os desempenhos permaneçam inferiores aos observados para Sentinel-2 e Landsat-8.

De forma geral, os resultados evidenciam clara superioridade dos sensores de maior resolução espacial na modelagem da distribuição da cafeicultura em Nepomuceno. O Sentinel-2 apresentou os melhores desempenhos em praticamente todas as métricas avaliadas, seguido pelo Landsat-8, enquanto o MODIS apresentou limitações mais evidentes, especialmente na identificação correta das áreas de presença do café. Esse comportamento está diretamente relacionado à capacidade dos sensores de representar adequadamente paisagens agrícolas heterogêneas, nas quais pequenas variações topográficas e estruturais do dossel vegetativo desempenham papel fundamental na discriminação espectral da cultura (Pettorelli *et al.*, 2014; Nagendra, 2001). Além disso, os resultados demonstram que a remoção criteriosa de variáveis redundantes pode favorecer modelos mais parcimoniosos, reduzindo a complexidade computacional sem perdas substanciais de desempenho preditivo (Dormann *et al.*, 2013).

Tabela 5.2 – Métricas de validação dos modelos baseados em diferentes sensores orbitais para o município de Patrocínio.

Satélite	Etapas	Acurácia	Sensibilidade	Especificidade	Kappa
Sentinel-2	Original	0,801	0,832	0,768	0,601
	Removal_1	0,809	0,815	0,803	0,618
	Removal_2	0,815	0,864	0,763	0,629
Landsat-8	Original	0,720	0,743	0,697	0,440
MODIS	Original	0,716	0,702	0,730	0,431
	Removal_1	0,674	0,646	0,702	0,347

Fonte: Elaborado pelo autor (2026).

Para o município de Patrocínio Tabela 5.2, observou-se comportamento distinto entre os sensores orbitais quanto à capacidade de discriminação espacial da cafeicultura, evidenciando forte influência da resolução espacial, espectral e da composição dos preditores ambientais uti-

lizados nos modelos MaxEnt. Os modelos baseados em imagens do Sentinel-2 apresentaram os melhores desempenhos globais entre os sensores avaliados, especialmente após a remoção seletiva de variáveis redundantes. O modelo original apresentou Acurácia de 0,801, Sensibilidade de 0,832, Especificidade de 0,768 e coeficiente Kappa de 0,601. Após a primeira etapa de remoção (Remoção-1), houve incremento no desempenho geral do modelo, com Acurácia de 0,809, Sensibilidade de 0,815, Especificidade de 0,803 e Kappa de 0,618, indicando maior equilíbrio entre a capacidade de detectar corretamente áreas cafeeiras e áreas não cafeeiras.

O melhor desempenho foi observado no modelo Remoção-2, que apresentou Acurácia de 0,815, Sensibilidade de 0,864, Especificidade de 0,763 e coeficiente Kappa de 0,629. Esses resultados sugerem que a retirada de variáveis com baixa contribuição favoreceu a capacidade preditiva do modelo, reduzindo redundâncias e possíveis efeitos de multicolinearidade entre os preditores ambientais (Dormann *et al.*, 2013). O aumento da sensibilidade indica melhora na identificação de áreas com ocorrência de café, embora acompanhado de discreta redução da especificidade, sugerindo maior tendência do modelo em classificar áreas como adequadas ao cultivo. Ainda assim, o equilíbrio geral entre os indicadores evidencia boa capacidade discriminatória do Sentinel-2 para representar padrões espectrais associados à cafeicultura.

O elevado desempenho do Sentinel-2 pode ser atribuído principalmente à sua resolução espacial de 10–20 m e à presença das bandas *red-edge*, altamente sensíveis às alterações fisiológicas e estruturais da vegetação (Drusch *et al.*, 2012). Essas bandas permitem melhor discriminação do vigor vegetativo, biomassa foliar e estrutura do dossel cafeeiro, favorecendo a representação de áreas agrícolas heterogêneas, especialmente em sistemas produtivos com elevada variabilidade intraespacial.

Os modelos desenvolvidos com o sensor Landsat-8 apresentaram desempenho intermediário, com Acurácia de 0,720, Sensibilidade de 0,743, Especificidade de 0,697 e coeficiente Kappa de 0,440. Embora os valores indiquem capacidade preditiva moderada, o desempenho inferior em relação ao Sentinel-2 sugere limitações associadas à resolução espacial de 30 m, que tende a aumentar o efeito de mistura espectral, especialmente em paisagens agrícolas heterogêneas. Em Patrocínio, apesar da predominância de áreas agrícolas mais extensas, a variabilidade do mosaico agrícola e a presença de diferentes usos do solo ainda podem reduzir a precisão do mapeamento quando se utilizam pixels de maior dimensão (Pettorelli *et al.*, 2014).

Além disso, a menor resolução espectral do Landsat-8 em comparação ao Sentinel-2 limita parcialmente a capacidade de detectar variações sutis relacionadas ao estado fisiológico do

cafeeiro. Ainda assim, a presença das bandas do infravermelho próximo (*NIR*), infravermelho de ondas curtas (*SWIR*) e térmicas contribui significativamente para representar padrões de umidade, biomassa e temperatura superficial associados ao desenvolvimento da cultura (Pettorelli *et al.*, 2014).

Os modelos desenvolvidos com o sensor MODIS apresentaram os menores desempenhos entre os sensores avaliados. O modelo original apresentou Acurácia de 0,716, Sensibilidade de 0,702, Especificidade de 0,730 e coeficiente *Kappa* de 0,431, enquanto o modelo Remoção-1 apresentou redução adicional do desempenho, com Acurácia de 0,674, Sensibilidade de 0,646, Especificidade de 0,702 e *Kappa* de 0,347. Diferentemente do observado no Sentinel-2, a remoção de variáveis no MODIS resultou em perda de desempenho, indicando que mesmo variáveis com contribuição aparentemente reduzida desempenhavam papel complementar na construção da superfície de adequabilidade do modelo.

O desempenho inferior do MODIS está diretamente relacionado à sua resolução espacial mais grosseira, da ordem de 250 m, o que favorece forte mistura espectral entre diferentes coberturas do solo dentro de um mesmo pixel (Nagendra, 2001). Em áreas agrícolas heterogêneas, um único pixel pode incluir simultaneamente cafeeiros, pastagens, vegetação nativa e solo exposto, reduzindo significativamente a capacidade do modelo em discriminar corretamente áreas de cultivo. Como consequência, observa-se redução tanto da sensibilidade quanto do coeficiente *Kappa*, indicando menor concordância entre valores previstos e observados.


De maneira geral, os resultados demonstram que os modelos baseados em sensores de maior resolução espacial e espectral apresentaram desempenho superior, sendo o Sentinel-2 o sensor mais eficiente para representar a distribuição espacial da cafeicultura em Patrocínio. A melhora progressiva observada após a remoção de variáveis no Sentinel-2 evidencia ainda a importância da seleção criteriosa de preditores ambientais, mostrando que modelos mais parcimoniosos podem apresentar melhor capacidade de generalização espacial sem perda de desempenho (Merow; Smith; Silander, 2013; Elith *et al.*, 2011). Em contrapartida, sensores de resolução espacial mais baixa, como o MODIS, demonstraram limitações na representação da heterogeneidade ambiental, reforçando que a escolha do sensor deve considerar simultaneamente a escala espacial da análise, a estrutura da paisagem agrícola e a complexidade espectral do alvo mapeado.

5.3.1 Mapas binários de presença de Café

Com base na probabilidade de presença de cafeeiros nos municípios (Figura 5.7 para Nepomuceno e Figura 5.8 para Patrocínio), os limiares foram definidos considerando a variabilidade dos modelos, priorizando aqueles obtidos a partir das configurações com maior índice Kappa, garantindo maior confiabilidade na discriminação entre presença e ausência (Allouche; Tsoar; Kadmon, 2006).


A aplicação desses limiares permitiu estimar a área classificada como de alta probabilidade de presença de café (>50%) em cada município. Observou-se que a utilização da combinação de variáveis altimétricas e bandas de sentinel-2, resultou em desempenho superior na avaliação e validação dos modelos, produzindo mapas mais confiáveis e robustos para Nepomuceno, porém para Patrocínio o modelo baseado em variáveis bioclimáticas e bandas de sentinel-2 apresentou o melhor desempenho para as métricas estabelecidas.

Figura 5.7 – Mapa binário de distribuição de cultivos em Nepomuceno.



Fonte: Elaborado pelo autor (2026).

Figura 5.8 – Mapa contínuo de distribuição de cultivos em patrocínio



Fonte: Elaborado pelo autor(2026).

6 CONCLUSÃO

Os resultados demonstraram que, apesar das diferenças espectrais, climáticas e topográficas entre os municípios de Patrocínio e Nepomuceno, os modelos baseados no algoritmo MaxEnt foram capazes de representar adequadamente os fatores condicionantes da distribuição espacial da cafeicultura. Esse comportamento evidencia que a modelagem ajustada às características ambientais locais contribui para maior precisão e interpretabilidade dos modelos de adequabilidade.

Os modelos apresentaram desempenho classificado como bom a excelente em diferentes esquemas de particionamento dos dados, evidenciando capacidade de generalização mesmo sob elevada variabilidade ambiental. Em Nepomuceno, observou-se maior contribuição das variáveis topográficas, refletindo a influência do relevo na organização espacial da cafeicultura em ambientes montanhosos. Em Patrocínio, as variáveis bioclimáticas e os modelos integrados apresentaram maior relevância, indicando maior influência dos gradientes climáticos regionais sobre a distribuição do cultivo.

A análise dos diferentes conjuntos de preditores demonstrou que a remoção de variáveis com contribuição próxima de zero nem sempre resultou em perdas significativas de desempenho. Isso ocorre porque, a cada remoção, o modelo é recalibrado, permitindo que outros preditores assumam maior contribuição explicativa. Dessa forma, valores reduzidos ou nulos de AUC-drop não implicam necessariamente irrelevância ecológica ou estatística da variável. Assim, a exclusão de preditores deve ser conduzida de forma criteriosa, considerando conjuntamente métricas de calibração e validação, de modo a identificar modelos mais parcimoniosos sem comprometer sua capacidade discriminatória.

Os resultados também evidenciaram diferenças consistentes entre sensores orbitais. De maneira geral, os melhores desempenhos foram obtidos com o Sentinel-2, refletindo a contribuição da maior resolução espacial e da disponibilidade de bandas *red-edge*, importantes para a discriminação do vigor vegetativo do cafeeiro. O Landsat-8 apresentou desempenho intermediário e estabilidade preditiva satisfatória, enquanto os modelos baseados em MODIS apresentaram menores valores de desempenho, especialmente em áreas heterogêneas, devido ao efeito de mistura espectral associado à resolução espacial mais grosseira.

De forma integrada, modelos com maiores valores de Kappa e AUC demonstraram melhor equilíbrio entre capacidade preditiva e confiabilidade, sendo mais adequados para o mape-

amento da cafeicultura. Esses resultados reforçam que a combinação entre seleção criteriosa de preditores, escolha adequada do sensor orbital e estratégias consistentes de particionamento dos dados é fundamental para obtenção de modelos MaxEnt robustos e espacialmente representativos.

Por fim, a metodologia adotada demonstrou elevado potencial de replicabilidade, podendo ser aplicada em outros municípios e períodos temporais, desde que haja disponibilidade de dados equivalentes. A integração entre modelagem MaxEnt, sensoriamento remoto e variáveis ambientais constitui uma abordagem promissora para o monitoramento espaço-temporal da cafeicultura, subsidiando o planejamento agrícola e a avaliação de mudanças associadas à dinâmica produtiva e às variações ambientais.

REFERÊNCIAS

- AALTO, I. J. *et al.* Strong influence of trees outside forest in regulating microclimate of intensively modified afro-montane landscapes. **Biogeosciences Discussions**, Göttingen, Germany, v. 2021, p. 1–34, 2021.
- ABASTECIMENTO, C. N. de. **Acompanhamento da Safra Brasileira: Café — 2º Levantamento, Maio 2023**. 2023. <https://www.conab.gov.br/info-agro/safras/cafe>. Acesso em: 31 maio 2025.
- ABDELAAL, M. *et al.* Predicting the potential current and future distribution of the endangered endemic vascular plant *Primula boveana* Decne. ex Duby in Egypt. **Plants**, MDPI, v. 9, n. 8, p. 957, 2020.
- ABIGABA, D. *et al.* The potential of agroforestry to buffer climate change impacts on suitability of coffee and banana in Uganda. **Agroforestry Systems**, Springer, v. 98, n. 6, p. 1555–1577, 2024.
- ADANE, A. Analysis of current and future bioclimatic suitability for C. arabica production in Ethiopia. **Plos one**, Public Library of Science San Francisco, CA USA, v. 19, n. 10, p. e0310945, 2024.
- ADRIAN, J.; SAGAN, V.; MAIMAITIJIANG, M. Sentinel SAR-optical fusion for crop type mapping using deep learning and Google Earth Engine. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 175, p. 215–235, 2021.
- ALLAHVERDIYAN, A. E. Validity of the maximum entropy principle in inference, and the origins of uncertainty. **Entropy**, MDPI, v. 23, n. 4, p. 484, 2021.
- ALLOUCHE, O.; TSOAR, A.; KADMON, R. Assessing the accuracy of species distribution models: prevalence, kappa and the true skill statistic (tss). **Journal of applied ecology**, Wiley Online Library, v. 43, n. 6, p. 1223–1232, 2006.
- ALVES, E. L.; PEREIRA, F. A. C.; DALCHIAVON, F. C. Potencial econômico da utilização de micro-terraceamento em lavouras de café: um estudo de caso. **Revista iPecege**, v. 3, n. 1, p. 24–38, 2017.
- ALVES, M. de C. *et al.* Multisensor analysis for environmental targets identification in the region of Funil Dam, State of Minas Gerais, Brazil. **Applied Geomatics**, Springer, v. 15, n. 4, p. 807–827, 2023.
- AMARO, G. *et al.* Efeito da extensão da área de estudo sobre a distribuição potencial de espécies: Um estudo com modelos MaxEnt para *Raoiella indica* Hirst (Acari: Tenuipalpidae) no Brasil. [s.d.].
- ANTHONY, F. *et al.* The origin of cultivated *Coffea arabica* L. varieties revealed by AFLP and SSR markers. **Theoretical and Applied Genetics**, Springer, v. 104, p. 894–900, 2002.
- ARAÚJO, M. B.; GUIBAN, A. Five (or so) challenges for species distribution modelling. **Journal of biogeography**, Wiley Online Library, v. 33, n. 10, p. 1677–1688, 2006.

- ARIA, M.; CUCCURULLO, C. bibliometrix: An r-tool for comprehensive science mapping analysis. **Journal of Informetrics**, v. 11, n. 4, p. 959–975, 2017. ISSN 1751-1577. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1751157717300500>.
- ASNER, G. P. Cloud cover in landsat observations of the brazilian amazon. **International journal of remote sensing**, Taylor & Francis, v. 22, n. 18, p. 3855–3862, 2001.
- BARROS, M. A.; MOREIRA, M. A.; RUDORFF, B. F. T. Dados interferométricos para modelagem topográfica e caracterização ambiental do café em escala municipal. **Sociedade & Natureza**, SciELO Brasil, v. 19, p. 33–50, 2007.
- BENSE, V.; BELTRAMI, H. Impact of horizontal groundwater flow and localized deforestation on the development of shallow temperature anomalies. **Journal of Geophysical Research: Earth Surface**, Wiley Online Library, v. 112, n. F4, 2007.
- BENTI, F. *et al.* Modeling coffee (*coffea arabica* l.) climate suitability under current and future scenario in jimma zone, ethiopia. **Environmental Monitoring and Assessment**, Springer, v. 194, n. 4, p. 271, 2022.
- BEVEN, K. J.; KIRKBY, M. J. A physically based, variable contributing area model of basin hydrology / un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. **Hydrological Sciences Journal**, Taylor & Francis, v. 24, n. 1, p. 43–69, 1979.
- BORAL, D.; MOKTAN, S. Predictive distribution modeling of *swertia bimaculata* in darjeeling-sikkim eastern himalaya using maxent: current and future scenarios. **Ecological Processes**, Springer, v. 10, n. 1, p. 26, 2021.
- BUCKLEY, L. B.; AL. *et.* Can niche-based distribution models outperform spatial interpolation? **Global Ecology and Biogeography**, Wiley, v. 19, n. 6, p. 613–620, 2010.
- BUNN, C. e. a. A bitter cup: climate change profile of global production of arabica and robusta coffee. **Climatic Change**, v. 129, n. 1, p. 89–101, 2015.
- BUNN, C. e. a. A bitter cup: climate change profile of global production of arabica and robusta coffee. **Climatic Change**, v. 129, n. 1, p. 89–101, 2015.
- CAMARGO, M. B. P. d. The impact of climatic variability and climate change on arabic coffee crop in brazil. **Bragantia**, SciELO Brasil, v. 69, p. 239–247, 2010.
- CANTON, H. Food and agriculture organization of the united nations—fao. In: **The Europa directory of international organizations 2021**. [S.l.]: Routledge, 2021. p. 297–305.
- CHAIN-GUADARRAMA, A. *et al.* Ecosystem services by birds and bees to coffee in a changing climate: A review of coffee berry borer control and pollination. **Agriculture, Ecosystems & Environment**, Elsevier, v. 280, p. 53–67, 2019.
- CHALCHISSA, F. B.; DIGA, G. M.; TOLOSSA, A. R. Modeling the responses of coffee (*coffea arabica* l.) distribution to current and future climate change in jimma zone, ethiopia. **SAINS TANAH-Journal of Soil Science and Agroclimatology**, v. 19, n. 1, p. 19–32, 2022.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. Mapping spatial variability of foliar nitrogen in coffee (*coffea arabica* l.) plantations with multispectral sentinel-2 msi data. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 138, p. 1–11, 2018.

CHUVIECO, E. **Fundamentals of Satellite Remote Sensing: An Environmental Approach**. 3rd. ed. [S.l.]: CRC Press, 2020.

CLAVERIE, M.; OUTROS. Superando limitações de cobertura de nuvens no sentinel-2 para mapeamento terrestre. **Remote Sensing of Environment**, v. 204, p. 15–27, 2018.

COHEN, I. *et al.* Pearson correlation coefficient. **Noise reduction in speech processing**, Springer, p. 1–4, 2009.

DAVIS, A. P. *et al.* High extinction risk for wild coffee species and implications for coffee sector sustainability. **Science advances**, American Association for the Advancement of Science, v. 5, n. 1, p. eaav3473, 2019.

DAVIS, A. P. *et al.* The impact of climate change on indigenous arabica coffee (*coffea arabica*): predicting future trends and identifying priorities. **PloS one**, Public Library of Science San Francisco, USA, v. 7, n. 11, p. e47981, 2012.

DIMOBE, K. *et al.* Climate change reduces the distribution area of the shea tree (*vitellaria paradoxa* cf *gaertn.*) in burkina faso. **Journal of Arid Environments**, Elsevier, v. 181, p. 104237, 2020.

DORMANN, C. F. *et al.* Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. **Ecography**, Wiley Online Library, v. 36, n. 1, p. 27–46, 2013.

DRUSCH, M. *et al.* Sentinel-2: Esa's optical high-resolution mission for gmes operational services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012.

ELITH, J.; LEATHWICK, J. R. Species distribution models: ecological explanation and prediction across space and time. **Annual review of ecology, evolution, and systematics**, Annual Reviews, v. 40, n. 1, p. 677–697, 2009.

ELITH, J. *et al.* A statistical explanation of maxent for ecologists. **Diversity and distributions**, Wiley Online Library, v. 17, n. 1, p. 43–57, 2011.

FAIN, S. J. *et al.* Climate change and coffee: Assessing vulnerability by modeling future climate suitability in the caribbean island of puerto rico. **Climatic Change**, Springer, v. 146, n. 1–2, p. 175–186, 2018.

FENG, X. *et al.* Collinearity in ecological niche modeling: Confusions and challenges. **Ecology and evolution**, Wiley Online Library, v. 9, n. 18, p. 10365–10376, 2019.

FERRIER, S. Mapping spatial pattern in biodiversity for regional conservation planning: where to from here? **Systematic biology**, Society of Systematic Zoology, v. 51, n. 2, p. 331–363, 2002.

FICK, S. E.; HIJMANS, R. J. Worldclim 2: new 1-km spatial resolution climate surfaces for global land areas. **International Journal of Climatology**, John Wiley & Sons, v. 37, n. 12, p. 4302–4315, 2017.

FIELDING, A.; BELL, J. A review of methods for the assessment of prediction errors in conservation presence/absence models. **Environmental Conservation**, v. 24, n. 1, p. 38–49, 2007.

- FIELDING, A. H.; BELL, J. F. A review of methods for the assessment of prediction errors in conservation presence/absence models. **Environmental conservation**, Cambridge University Press, v. 24, n. 1, p. 38–49, 1997.
- FITZGIBBON, A.; PISUT, D.; FLEISHER, D. Evaluation of maximum entropy (maxent) machine learning model to assess relationships between climate and corn suitability. **Land**, MDPI, v. 11, n. 9, p. 1382, 2022.
- FOODY, G. M. Valuing map validation: The need for rigorous land cover map accuracy assessment. **Landscape and Urban Planning**, v. 143, p. 1–6, 2015.
- Garnier *et al.* **viridis(Lite) - Colorblind-Friendly Color Maps for R**. [S.l.], 2024. Viridis package version 0.6.5. Disponível em: <https://sjmgarnier.github.io/viridis/>.
- GERONIMO-ISIDRO, F. *et al.* Spatiotemporal modeling of hemileia vastatrix using multiple machine learning algorithms: implications for disease surveillance of the coffee leaf rust disease in the philippines. **Journal of Plant Pathology**, Springer, p. 1–16, 2025.
- GIRALDO-SANCLEMENTE, W. *et al.* Coffee yield is influenced by soil properties, not by nitrogen fertilization strategies, under greenhouse gas monitoring in a costa rican andisol. **Frontiers in Agronomy**, Frontiers Media SA, v. 7, p. 1729122, 2025.
- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from eos-modis. **Remote sensing of Environment**, Elsevier, v. 58, n. 3, p. 289–298, 1996.
- GOMES, L. C. *et al.* Agroforestry systems can mitigate the impacts of climate change on coffee production: a spatially explicit assessment in brazil. **Agriculture, Ecosystems & Environment**, Elsevier, v. 294, p. 106858, 2020.
- GORELICK, N. *et al.* Google earth engine: Planetary-scale geospatial analysis for everyone. **Remote sensing of Environment**, Elsevier, v. 202, p. 18–27, 2017.
- GUO, Y. *et al.* Predicting the impacts of climate change, soils and vegetation types on the geographic distribution of polyporus umbellatus in china. **Science of the Total Environment**, Elsevier, v. 648, p. 1–11, 2019.
- HAILU, B. T. *et al.* Assessing spatial distribution of coffea arabica l. in ethiopia's highlands using species distribution models and geospatial analysis methods. **Ecological Informatics**, Elsevier, v. 42, p. 79–89, 2017.
- HENGL, T. *et al.* Soilgrids250m: Global gridded soil information based on machine learning. **PLoS one**, Public Library of Science San Francisco, CA USA, v. 12, n. 2, p. e0169748, 2017.
- HIJMANS, R. J.; BROWN, A.; BARBOSA, M. **terra: Spatial Data Analysis**. [S.l.], 2026. R package version 1.9-1. Disponível em: <https://CRAN.R-project.org/package=terra>.
- HIJMANS, R. J. *et al.* Very high resolution interpolated climate surfaces for global land areas. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, Wiley Online Library, v. 25, n. 15, p. 1965–1978, 2005.
- HIJMANS, R. J.; ELITH, J. Species distribution models. **Spatial Data Science (rspatial. org)**. Available online at <https://rspatial.org/sdm> [Google Scholar], 2021.

HONG, D. *et al.* More diverse means better: Multimodal deep learning meets remote-sensing imagery classification. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 59, n. 5, p. 4340–4354, 2020.

HUETE, A. R. *et al.* Overview of the radiometric and biophysical performance of the modis vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 195–213, 2002.

HUNT, D. A. *et al.* Review of remote sensing methods to map coffee production systems. **Remote Sensing**, MDPI, v. 12, n. 12, p. 2041, 2020.

Instituto Brasileiro de Geografia e Estatística (IBGE). **Cidades e Estados**. 2022. <https://www.ibge.gov.br/cidades-e-estados.html>. Acesso em: 15 jun. 2025.

International Coffee Organization. **The Economics of Coffee**. 2023. <https://ico.org>. Acesso em: 31 maio 2025.

JAYAKUMAR, M. *et al.* Impact of climate variability on coffee yield in india—with a micro-level case study using long-term coffee yield data of humid tropical kerala. **Climatic Change**, Springer, v. 145, p. 335–349, 2017.

JAYNES, E. T. **Probability Theory: The Logic of Science**. [S.l.]: Cambridge University Press, 1990. Published posthumously.

JHA, S.; VANDERMEER, J. Impacts of coffee agroforestry management on tropical bee communities. **Biological Conservation**, Elsevier, v. 143, n. 6, p. 1423–1431, 2010.

JIMÉNEZ, A. A. *et al.* Potential coffee distribution in a central-western region of mexico. **Ecologies**, MDPI, v. 4, n. 2, p. 269–287, 2023.

JIMÉNEZ-VALVERDE, A. e. a. Limitations of niche-based models in ecological applications: a review. **Diversity and Distributions**, v. 14, n. 3, p. 167–176, 2008.

JÚNIOR, F. V. de C. *et al.* Agroclimatic and mechanization zoning of sugarcane associated with ethanol production potential in minas gerais under climate change scenarios. **Journal of Geovisualization and Spatial Analysis**, Springer, v. 9, n. 1, p. 25, 2025.

JUSTICE, C. *et al.* The modis fire products. **Remote sensing of Environment**, Elsevier, v. 83, n. 1-2, p. 244–262, 2002.

KAMYO, T.; ASANOK, L. Modeling habitat suitability of dipterocarpus alatus (dipterocarpaceae) using maxent along the chao phraya river in central thailand. **Forest Science and Technology**, Taylor & Francis, v. 16, n. 1, p. 1–7, 2020.

KASSAMBARA, A.; KASSAMBARA, M. A. Package ‘ggcorrplot’. **R package version 0.1**, v. 3, n. 3, p. 908, 2019.

KATH, J. *et al.* Temperature and rainfall impacts on robusta coffee bean characteristics. **Climate Risk Management**, Elsevier, v. 32, p. 100281, 2021.

KOU, J. *et al.* The moss genus didymodon as an indicator of climate change on the tibetan plateau. **Ecological Indicators**, Elsevier, v. 113, p. 106204, 2020.

- LÄDERACH, P. *et al.* Climate change adaptation of coffee production in space and time. **Climatic change**, Springer, v. 141, n. 1, p. 47–62, 2017.
- LAMMEY, R. Using the crossref metadata api to explore publisher content. **Science Editing**, Korean Council of Science Editors, v. 3, n. 2, p. 109–111, 2016.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **biometrics**, JSTOR, p. 159–174, 1977.
- LEBOEUF, J. Practical applications of remote sensing technology—an industry perspective. **HortiTech**, 2000.
- LI, C.; BACIU, G.; WANG, Y. Module-based visualization of large-scale graph network data. **Journal of visualization**, Springer, v. 20, n. 2, p. 205–215, 2017.
- LI, H. e. a. Maxent-based modeling and climate change risk assessment for coffea arabica in southwest china. **Environmental and Ecological Statistics**, 2024.
- LOBO, J. M.; JIMÉNEZ-VALVERDE, A.; REAL, R. Assessing the effect of the extent of the study area on the accuracy of species distribution models: a case study with iberian amphibians and reptiles. **Ecological Modelling**, Elsevier, v. 210, n. 3, p. 478–486, 2008.
- LOPES, K. C. M. Alterações químicas em grãos in natura de café arábica de altitude promovidas por fermentação controlada. Alegre, 2025.
- LUZ, M. P. S. *et al.* Aptidão da colheita mecanizada em lavouras cafeeiras no município de carmo de minas, mg. Embrapa Café, 2015.
- MALVINO, S.; SILVA, E. Análise climática do município de patrocínio (mg). **Caminhos de Geografia**, v. 10, n. 16, p. 93–108, 2005.
- MARCO, P. D.; NÓBREGA, C. C. Evaluating collinearity effects on species distribution models: An approach based on virtual species simulation. **PloS one**, Public Library of Science San Francisco, CA USA, v. 13, n. 9, p. e0202403, 2018.
- MERLE, I. *et al.* Microclimate estimation under different coffee-based agroforestry systems using full-sun weather data and shade tree characteristics. **European Journal of Agronomy**, Elsevier, v. 132, p. 126396, 2022.
- MEROW, C.; SMITH, M.; SILANDER, J. A practical guide to maxent for modeling species' distributions: what it does, and why inputs and settings matter. **Ecography**, v. 36, n. 10, p. 1058–1069, 2013.
- MOREIRA, S. L. *et al.* Intercropping of coffee with the palm tree, macauba, can mitigate climate change effects. **Agricultural and forest meteorology**, Elsevier, v. 256, p. 379–390, 2018.
- MUSHTAQ, S. *et al.* Modelled distribution of an invasive alien plant species differs at different spatiotemporal scales under changing climate: a case study of parthenium hysterophorus l. **Tropical Ecology**, Springer, v. 62, n. 3, p. 398–417, 2021.
- NAGENDRA, H. Using remote sensing to assess biodiversity. **International journal of remote sensing**, Taylor & Francis, v. 22, n. 12, p. 2377–2400, 2001.

- NAIR, P. R.; KUMAR, B. M.; NAIR, V. D. **An introduction to agroforestry: four decades of scientific developments**. [S.l.]: Springer, 2021.
- OLIVEIRA, K. R. *et al.* Influence of temperature and altitude on the expansion of coffee crops in matas de minas, brazil. *Revista Engenharia na Agricultura*, 2020.
- OSMAN, K. T. Physical properties of soil. In: **Soils: Principles, properties and management**. [S.l.]: Springer, 2012. p. 49–65.
- OVALLE-RIVERA, O. *et al.* Projected shifts in coffea arabica suitability among major global producing regions due to climate change. **PloS one**, Public Library of Science San Francisco, CA USA, v. 10, n. 4, p. e0124155, 2015.
- PAGE, M. J. *et al.* The prisma 2020 statement: an updated guideline for reporting systematic reviews. **bmj**, British Medical Journal Publishing Group, v. 372, 2021.
- PEARCE, J.; FERRIER, S. Evaluating the predictive performance of habitat models developed using logistic regression. **Ecological modelling**, Elsevier, v. 133, n. 3, p. 225–245, 2000.
- PEBESMA, E. *et al.* Simple features for r. **Journal of Statistical Software**, v. 90, n. 1, p. 1–31, 2018.
- PEDERSEN, T. L. **patchwork: The Composer of Plots**. [S.l.], 2025. R package version 1.3.2. Disponível em: <https://CRAN.R-project.org/package=patchwork>.
- PETERSON, A. T. Predicting the geography of species' invasions via ecological niche modeling. **The quarterly review of biology**, The University of Chicago Press, v. 78, n. 4, p. 419–433, 2003.
- PETERSON, A. T.; SOBERÓN, J. Species distribution modeling and ecological niche modeling: getting the concepts right. **Natureza & Conservação**, v. 10, n. 2, p. 102–107, 2012.
- PETITPIERRE, B. *et al.* Selecting predictors to maximize the transferability of species distribution models: Lessons from cross-continental plant invasions. **Global Ecology and Biogeography**, Wiley Online Library, v. 26, n. 3, p. 275–287, 2017.
- PETTORELLI, N. *et al.* Satellite remote sensing for applied ecologists: opportunities and challenges. **Journal of Applied Ecology**, Wiley Online Library, v. 51, n. 4, p. 839–848, 2014.
- PHILLIPS, S. J.; ANDERSON, R. P.; SCHAPIRE, R. E. Maximum entropy modeling of species geographic distributions. **Ecological modelling**, Elsevier, v. 190, n. 3–4, p. 231–259, 2006.
- PHILLIPS, S. J.; DUDÍK, M. A maximum entropy approach to species distribution modeling. **Proceedings of the Twenty-First International Conference on Machine Learning**, ACM, p. 655–662, 2004.
- PHILLIPS, S. J. *et al.* Sample selection bias and presence-only distribution models: implications for background and pseudo-absence data. **Ecological Applications**, v. 19, n. 1, p. 181–197, 2009.

- PHILLIPS, S. J.; DUDÍK, M.; SCHAPIRE, R. E. Modeling of species distributions with maxent: new extensions and a comprehensive evaluation. **Ecography**, Wiley, v. 31, n. 2, p. 161–175, 2008.
- PHIRI, D. *et al.* Sentinel-2 data for land cover/use mapping: A review. **Remote sensing**, Mdpi, v. 12, n. 14, p. 2291, 2020.
- PIMENTEL-GOMES, F. **Curso de Estatística Experimental**. Piracicaba: FEALQ, 2000.
- POGGIO, L. *et al.* Soilgrids 2.0: producing soil information for the globe with quantified spatial uncertainty. **Soil**, Copernicus Publications Göttingen, Germany, v. 7, n. 1, p. 217–240, 2021.
- QUISPE, K. *et al.* Spatial analysis of soil acidity and available phosphorus in coffee-growing areas of pichanaqui: implications for liming and site-specific fertilization. **Agriculture**, MDPI, v. 15, n. 15, p. 1632, 2025.
- RICE, R. A. Fruits from shade trees in coffee: how important are they? **Agroforestry systems**, Springer, v. 83, p. 41–49, 2011.
- RONG, Z. *et al.* Modeling the effect of climate change on the potential distribution of qinghai spruce (*picea crassifolia* kom.) in qilian mountains. **Forests**, MDPI, v. 10, n. 1, p. 62, 2019.
- SALOMONSON, V.; TOLL, D. spectral band characteristics of the eos moderate resolution imaging spectrometer (modis-n) facility instrument. **Advances in Space Research**, v. 2, n. 3, p. 231–236, 1990.
- SALOMONSON, V. V. *et al.* Modis-advanced facility instrument for studies of the earth as a system. 1987.
- SARVINA, Y. *et al.* Projection of robusta coffee's climate suitability for sustainable indonesian coffee production. **International Journal of Sustainable Development & Planning**, v. 18, n. 4, 2023.
- SCHNEIDER, B. de O.; ALVES, M. de C.; FERREIRA, V. A. Coffee crop detection and mapping using sentinel-2 data and spatial coherence. **Theoretical and Applied Engineering**, v. 9, n. 3, 2025.
- SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, v. 27, n. 3, p. 379–423, 1948.
- SILLERO, N.; BARBOSA, A. M. Common mistakes in ecological niche models. **International Journal of Geographical Information Science**, Taylor & Francis, v. 35, n. 2, p. 213–226, 2021.
- SINGH, P.; SARAN, S.; KOCAMAN, S. Role of maximum entropy and citizen science to study habitat suitability of jacobin cuckoo in different climate change scenarios. **ISPRS International Journal of Geo-Information**, MDPI, v. 10, n. 7, p. 463, 2021.
- SOARES, A. d. S. *et al.* Detecção precoce da ferrugem do cafeeiro causada por *hemileia vastatrix* a partir de imagens multiespectrais. Universidade Federal de Uberlândia, 2022.

SOUZA, C. G. *et al.* Multitemporal variables for the mapping of coffee cultivation areas. **Pesquisa Agropecuária Brasileira**, SciELO Brasil, v. 54, p. e00017, 2019.

STRAHLER, A. *et al.* Modis land cover and land-cover change products algorithm theoretical basis document (atbd). version 5.0. **Center for Remote Sensing, Department of Geography, Boston University, May, 72p**, 1999.

SWETS, J. A. Measuring the accuracy of diagnostic systems. **Science**, American Association for the Advancement of Science, v. 240, n. 4857, p. 1285–1293, 1988.

TAMIMINIA, H. *et al.* Google earth engine for geo-big data applications: A meta-analysis and systematic review. **ISPRS journal of photogrammetry and remote sensing**, Elsevier, v. 164, p. 152–170, 2020.

TEAM, R. C. *et al.* R: A language and environment for statistical computing. **R foundation for statistical computing, Vienna, Austria**, 2021.

THAPA, S. *et al.* Will climate change impact distribution of bats in nepal himalayas? a case study of five species. **Global Ecology and Conservation**, Elsevier, v. 26, p. e01483, 2021.

THENKABAIL, P. S.; LYON, J. G.; HUETE, A. Advances in hyperspectral remote sensing of vegetation and agricultural crops. In: **Fundamentals, sensor systems, spectral libraries, and data mining for vegetation**. [S.l.]: CRC press, 2018. p. 3–37.

THIOUNE, E.-H. *et al.* Temperature impacts the response of coffea canephora to decreasing soil water availability. **Tropical Plant Biology**, Springer, v. 13, p. 236–250, 2020.

TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A review on uav-based applications for precision agriculture. **Information**, MDPI, v. 10, n. 11, p. 349, 2019.

U.S. Department of Agriculture. **Production - Coffee**. 2024. <https://www.fas.usda.gov/data/production/commodity/0711100>. Acesso em: 31 maio 2025.

U.S. Department of Agriculture. **Production - Coffee**. 2024. <https://www.fas.usda.gov/data/production/commodity/0711100>. Acesso em: 31 maio 2025.

VOSSEN, H. Van der; BERTRAND, B.; CHARRIER, A. Next generation variety development for sustainable production of arabica coffee (coffea arabica l.): a review. **Euphytica**, Springer, v. 204, n. 2, p. 243–256, 2015.

WANG, J.; LI, X.; ZHANG, R. Evaluation of the modified chlorophyll absorption in reflectance index (mcari) for crop stress detection using sentinel-2 imagery. **Remote Sensing of Environment**, v. 243, p. 111763, 2020. Este estudo avalia o índice MCARI para detecção de estresse em culturas agrícolas usando dados do Sentinel-2, demonstrando sua eficácia na estimativa de clorofila e saúde da vegetação.

WEI, Y. *et al.* Chinese caterpillar fungus (ophiocordyceps sinensis) in china: Current distribution, trading, and futures under climate change and overexploitation. **Science of the Total Environment**, Elsevier, v. 755, p. 142548, 2021.

WEN, J. *et al.* The main inherent uncertainty sources in trend estimation based on satellite remote sensing data. **Theoretical and Applied Climatology**, Springer, v. 151, n. 1, p. 915–934, 2023.

- WICKHAM, H. ggplot2. **Wiley interdisciplinary reviews: computational statistics**, Wiley Online Library, v. 3, n. 2, p. 180–185, 2011.
- WICKHAM, H.; WICKHAM, M. H. Package ‘plyr’. **A Grammar of Data Manipulation. R package version**, v. 8, 2019.
- XIE, Q.; SUN, Y.; LI, H. Assessment of vegetation reflectance indices for characterizing crop canopy dynamics from multi-sensor remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, v. 78, p. 212–224, 2019. Analisa diferentes índices de vegetação derivados de sensores ópticos e sua relação com a dinâmica do dossel de culturas, incluindo índices sensíveis à clorofila e vigor vegetativo.
- XIONG, X.; BARNES, W. An overview of modis radiometric calibration and characterization. **Advances in Atmospheric Sciences**, Springer, v. 23, n. 1, p. 69–79, 2006.
- XU, N. *et al.* Assessing the suitable cultivation areas for scutellaria baicalensis in china using the maxent model and multiple linear regression. **Biochemical Systematics and Ecology**, Elsevier, v. 90, p. 104052, 2020.
- YANG, J. *et al.* Potential geographic distribution of relict plant pteroceltis tatarinowii in china under climate change scenarios. **Plos One**, Public Library of Science San Francisco, CA USA, v. 17, n. 4, p. e0266133, 2022.
- ZHANG, K.; ZHANG, Y.; TAO, J. Predicting the potential distribution of paeonia veitchii (paeoniaceae) in china by incorporating climate change into a maxent model. **Forests**, MDPI, v. 10, n. 2, p. 190, 2019.
- ZHANG, S. *et al.* Maximum entropy modeling for the prediction of potential plantation distribution of arabica coffee under the cmip6 mode in yunnan, southwest china. **Atmosphere**, MDPI, v. 13, n. 11, p. 1773, 2022.
- ZHEN-JIANG, Q.; GUANG-SHENG, Z. Regionalization of climatic suitability for major kiwifruit cultivars in china. **Chinese Journal of Agrometeorology**, v. 38, n. 04, p. 257, 2017.
- ZHU, Z.; WANG, S.; WOODCOCK, C. E. Improvement and expansion of the fmask algorithm: Cloud, cloud shadow, and snow detection for landsats 4–7, 8, and sentinel 2 images. **Remote sensing of Environment**, Elsevier, v. 159, p. 269–277, 2015.

7 APÊNDICE A

7.1 Índices espectrais utilizados na modelagem

Tabela 7.1 – Principais índices espectrais utilizados no mapeamento agrícola.

Índice	Fórmula	Referência
NDVI	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$	Huete (1988)
NDRE	$(\text{NIR} - \text{Red Edge}) / (\text{NIR} + \text{Red Edge})$	Gitelson (1997)
GNDVI	$(\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$	Gitelson (1996)
EVI	$2.5 * (\text{NIR} - \text{Red}) / (\text{NIR} + 6 * \text{Red} - 7.5 * \text{Blue} + 1)$	Huete (1988)
SAVI	$(1+L) * (\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red} + L)$	Huete (1988)
NDWI	$(\text{NIR} - \text{SWIR}) / (\text{NIR} + \text{SWIR})$	McFeeters (1996)
AVI	$\text{sqrt}(\text{NIR} * (\text{Red} + 0.5) * (\text{NIR} - \text{Red}))$	Zhou (2007)
MCARI	$((\text{RE} - \text{Red}) - 0.2 * (\text{RE} - \text{Green})) * \text{RE} / \text{Red}$	Daughtry (2000)
GLI	$(2 * G - R - B) / (2 * G + R + B)$	Louhaichi (2001)
TWI	$\ln(a / \tan(\text{beta}))$	Beven (1979)
SR	NIR / Red	Carlson (1997)


Fonte: Elaborado pelo autor (2026).

7.2 Fluxograma PRISMA

7.3 Estudos revisados sobre MaxEnt na cafeicultura

7.4 Estudos revisados sobre MaxEnt na cafeicultura

Figura 7.1 – Fluxograma PRISMA do processo de busca e seleção dos estudos incluídos na revisão.



Fonte: Elaborado pelo autor (2026).

Tabela 7.2 – Exemplos de estudos com MaxEnt em cafeicultura.

Referência	Objetivo / Aplicação	Software
Altamiranda (2024)	Áreas de risco de invasão e mudanças no nicho ecológico da praga	MaxEnt
Oliveira (2020)	Influência da temperatura e altitude na expansão das plantações	MaxEnt
Purba (2019)	Modelagem da área de plantação sob mudanças climáticas	MaxEnt
Ovalles (2015)	Mudanças projetadas na adequação do <i>C. arabica</i>	MaxEnt
Fekadu (2020)	Impactos das mudanças climáticas sobre espécies florestais em áreas cafeeiras	MaxEnt
Sarvina (2023)	Projeção da adequação climática do café robusta para sustentabilidade	MaxEnt
Zhang (2022)	Previsão da distribuição potencial de plantação de café arábica sob o CMIP6	MaxEnt
Abigaba (2024)	Potencial da agrofloresta para amortecer impactos das mudanças climáticas	MaxEnt
Gomes (2020)	Sistemas agroflorestais para mitigar impactos das mudanças climáticas na produção	MaxEnt
Jimenez (2023)	Distribuição potencial do café	MaxEnt
Guerrero (2025)	Distribuição dinâmica de <i>C. arabica</i> e <i>C. canephora</i> no México	MaxEnt
Jerronimo (2024)	Distribuição espaço-temporal de <i>Hemileia vastatrix</i> , agente da ferrugem do cafeeiro	MaxEnt
Benti (2022)	Modelagem da adequação climática do café sob cenários atuais e futuros	MaxEnt
Li (2024)	Modelagem para prever habitat potencial e áreas prioritárias de plantio	R (kuenm)
Ladarech (2017)	Adaptação da produção de café às mudanças climáticas no espaço e no tempo	MaxEnt
Adane (2024)	Análise da adequação bioclimática atual e futura para a produção de <i>C. arabica</i>	MaxEnt
Bunn (2025)	Avaliação econômica dos impactos climáticos	MaxEnt
Schroth (2015)	Adequabilidade climática do arábica na Indonésia	MaxEnt
Chalchissa (2022)	Resposta da distribuição de <i>Coffea arabica</i> às mudanças climáticas na Etiópia	MaxEnt
Zhang (2021)	Distribuição potencial do arábica na China sob cenários climáticos futuros	MaxEnt
Hailu (2017)	Avaliação da distribuição espacial de <i>Coffea arabica</i>	MaxEnt

Fonte: Elaborado pelo autor (2026).