ReGeo ISSN: 2177-3246

PROJEÇÃO FUTURA DA PROBABILIDADE DE OCORRÊNCIA DE INCÊNDIOS NO ESTADO DO PARÁ SOB DIFERENTES CENÁRIOS CLIMÁTICOS

FUTURE PROJECTION OF FIRE OCCURRENCE PROBABILITY IN THE STATE OF PARÁ, BRAZIL, UNDER DIFFERENT CLIMATE SCENARIOS

PROYECCIÓN FUTURA DE LA PROBABILIDAD DE OCURRENCIA DE INCENDIOS EN EL ESTADO DE PARÁ, BRASIL, BAJO DIFERENTES ESCENARIOS CLIMÁTICOS

https://doi.org/10.56238/revgeov17n11-147

Data de submissão: 25/10/2026 **Data de publicação:** 25/11/2026

Odaimys Socorro Ramos
Mestra em Ciências Ambientais
Instituição: Universidade Estadual de Feira de Santana (UEFS)
E-mail: ody.socorro@gmail.com

Udmilla Moura Contes Fortunato
Mestra em Ciências Ambientais
Instituição: Universidade Estadual de Feira de Santana (UEFS)
E-mail: udfortunato@gmail.com

Mariana Martins Medeiros de Santana
Doutora em Ecologia
Instituição: Universidade do Estado do Amapá (UEAP)
E-mail: mariana.medeiros@ueap.edu.br

Deorgia Tayane Mendes de Souza
Doutora em Geociências Aplicadas e Geodinâmica
Instituição: Universidade Estadual de Feira de Santana (UEFS)
E-mail: dtmsouza@uefs.br

Washington de Jesus Sant'Anna da Franca Rocha
Doutor em Geologia
Instituição: Universidade Estadual de Feira de Santana (UEFS)
E-mail: wrocha@uefs.br

Rodrigo Nogueira de Vasconcelos
Doutor em Ecologia
Instituição: Universidade Estadual de Feira de Santana (UEFS)
E-mail: rnv@uefs.br

RESUMO
Os incêndios florestais provocam impactos ambientais significativos, potencializados pelo aquecimento global, e o Pará está entre os estados de maior área queimada da Amazônia, mas faltam análises estaduais que projetem a resposta da probabilidade de fogo a cenários climáticos futuros. Este estudo teve como objetivo analisar a probabilidade de ocorrência de incêndios no estado do Pará e projetar possíveis alterações sob cenários climáticos futuros. O algoritmo de máxima entropia

(MaxEnt) foi ajustado com 1.000 pontos de cicatrizes de fogo do MapBiomas e 12 preditores não colineares (bioclimáticos do WorldClim 2.1, uso e cobertura da terra e distâncias a classes de uso) e projetado para 2021–2040 com os modelos MIROC6 e HadGEM3-GC31-LL, sob os cenários SSP1-2.6 e SSP5-8.5. O modelo de referência obteve AUC de 0,909. A distância às áreas agropecuárias foi o preditor mais importante (53,1%), seguida pela amplitude térmica anual (19,6%), e as variáveis antrópicas somaram cerca de 63% da contribuição. As classes moderada a muito alta ocuparam 30,4% do estado, concentradas no sul, sudeste e leste, e a agropecuária representou 62,65% e 87,14% das classes alta e muito alta. As projeções mantiveram esse padrão, com alterações de até 2,1 pontos percentuais por classe; o MIROC6 permaneceu próximo ao cenário de referência, enquanto o HadGEM3-GC31-LL indicou redução das classes muito baixa e baixa e aumento das classes moderada e alta. A probabilidade de fogo no Pará é governada sobretudo pela fronteira agropecuária, modulada pelo clima, o que indica as áreas de expansão agropecuária e o entorno das unidades de conservação como prioritários para a prevenção. As estimativas representam probabilidade ambiental de ocorrência, não previsão de incêndios, e não incorporam cenários futuros de uso da terra.

Palavras-chave: Dinâmica do Fogo. MaxEnt. Mudanças Climáticas. Amazônia. Uso e Cobertura da Terra.

ABSTRACT

Wildfires cause significant environmental impacts that are amplified by global warming, and Pará is among the Amazonian states with the largest burned area, yet state-level analyses projecting how fire probability may respond to future climate scenarios are lacking. This study aimed to analyze the probability of fire occurrence in the state of Pará and to project possible changes under future climate scenarios. The maximum entropy algorithm (MaxEnt) was fitted with 1,000 MapBiomas burned-scar points and 12 non-collinear predictors (WorldClim 2.1 bioclimatic variables, land use and land cover, and distances to land-use classes) and projected to 2021–2040 with the MIROC6 and HadGEM3-GC31-LL models under the SSP1-2.6 and SSP5-8.5 scenarios. The baseline model reached an AUC of 0.909. Distance to agricultural areas was the most important predictor (53.1%), followed by annual temperature range (19.6%), and anthropogenic variables accounted for about 63% of the contribution. Moderate to very high classes covered 30.4% of the state, concentrated in the south, southeast and east, and agriculture represented 62.65% and 87.14% of the high and very high classes. Projections preserved this pattern, with changes of up to 2.1 percentage points per class; MIROC6 remained close to the baseline, whereas HadGEM3-GC31-LL indicated a reduction of the very low and low classes and an increase of the moderate and high classes. Fire probability in Pará is governed mainly by the agricultural frontier, modulated by climate, which points to areas of agricultural expansion and the surroundings of protected areas as priorities for prevention. The estimates represent environmental probability of occurrence, not fire forecasts, and do not include future land-use scenarios.

Keywords: Fire Dynamics. MaxEnt. Climate Change. Amazon. Land Use and Land Cover.

RESUMEN

Los incendios forestales provocan impactos ambientales significativos, potenciados por el calentamiento global, y Pará está entre los estados amazónicos con mayor área quemada, pero faltan análisis estatales que proyecten la respuesta de la probabilidad de fuego a escenarios climáticos futuros. Este estudio tuvo como objetivo analizar la probabilidad de ocurrencia de incendios en el estado de Pará y proyectar posibles cambios bajo escenarios climáticos futuros. El algoritmo de máxima entropía (MaxEnt) se ajustó con 1.000 puntos de cicatrices de fuego de MapBiomas y 12 predictores no colineales (bioclimáticos de WorldClim 2.1, uso y cobertura de la tierra y distancias a clases de uso) y se proyectó para 2021–2040 con los modelos MIROC6 y HadGEM3-GC31-LL, bajo los escenarios

SSP1-2.6 y SSP5-8.5. El modelo de referencia obtuvo un AUC de 0,909. La distancia a las áreas agropecuarias fue el predictor más importante (53,1%), seguida por la amplitud térmica anual (19,6%), y las variables antrópicas sumaron cerca del 63% de la contribución. Las clases moderada a muy alta ocuparon el 30,4% del estado, concentradas en el sur, sureste y este, y la agropecuaria representó el 62,65% y el 87,14% de las clases alta y muy alta. Las proyecciones mantuvieron ese patrón, con cambios de hasta 2,1 puntos porcentuales por clase; MIROC6 permaneció cercano al escenario de referencia, mientras que HadGEM3-GC31-LL indicó reducción de las clases muy baja y baja y aumento de las clases moderada y alta. La probabilidad de fuego en Pará está gobernada sobre todo por la frontera agropecuaria, modulada por el clima, lo que señala las áreas de expansión agropecuaria y el entorno de las unidades de conservación como prioritarias para la prevención. Las estimaciones representan probabilidad ambiental de ocurrencia, no pronóstico de incendios, y no incorporan escenarios futuros de uso de la tierra.

Palabras clave: Dinámica del Fuego. MaxEnt. Cambio Climático. Amazonía. Uso y Cobertura de la Tierra.

1 INTRODUÇÃO

A Amazônia tem sido o bioma brasileiro com o maior número de incêndios ativos nas últimas duas décadas, apresentando, em média, quase duas vezes mais registros do que o bioma Cerrado (Silveira *et al.*, 2020). Essa situação está associada a fatores antrópicos, como o desmatamento para expansão agropecuária e o uso do fogo na manutenção de pastagens e no preparo de áreas agrícolas. As queimadas intencionais podem escapar das áreas manejadas e atingir florestas adjacentes, especialmente em paisagens degradadas (Neves *et al.*, 2018). Além disso, as secas aumentam a suscetibilidade da vegetação ao fogo, enquanto os incêndios recorrentes e a perda de cobertura florestal comprometem a biodiversidade e os estoques de carbono (Morton *et al.*, 2013). Em anos de seca extrema, as emissões de carbono dos incêndios florestais na Amazônia brasileira alcançam mais da metade das emissões do desmatamento, mesmo com a redução das taxas de desmatamento (Aragão *et al.*, 2018), e a degradação por fogo, bordas e exploração madeireira já afeta uma área comparável à do próprio desmatamento (Lapola *et al.*, 2023).

A dinâmica dos incêndios na Amazônia resulta da interação entre condições climáticas, características ecológicas da vegetação e transformações na paisagem. As florestas tropicais úmidas apresentam elevada sensibilidade ao fogo, pois muitas de suas espécies possuem baixa tolerância a esse distúrbio, podendo ocorrer alterações na estrutura e na composição da vegetação após incêndios recorrentes (Pivello, 2011). Silvestrini *et al.* (2011) demonstraram que a combinação entre mudanças no uso da terra e alterações climáticas favorece o aumento da atividade do fogo durante eventos de seca extrema, sobretudo nas proximidades de áreas agrícolas na borda sul da Amazônia.

As projeções futuras dos regimes de fogo apontam para possíveis mudanças na distribuição e na intensidade da atividade de queimadas em diferentes setores da Amazônia, incluindo regiões onde a probabilidade atual de ocorrência é relativamente baixa (Brando *et al.*, 2020). Entretanto, as respostas projetadas podem variar conforme as condições climáticas, ambientais e os cenários considerados (Moritz *et al.*, 2012). Essas incertezas reforçam a necessidade de análises espacialmente explícitas que permitam identificar áreas que no futuro possam ser potencialmente mais suscetíveis.

Nesse contexto, os modelos de aprendizado de máquina têm sido empregados na modelagem da probabilidade de ocorrência de incêndios, permitindo analisar a influência de diferentes variáveis ambientais e climáticas sobre sua distribuição espacial (Jain *et al.*, 2020; Iban; Sekertekin, 2022). A capacidade de integrar múltiplos preditores possibilita identificar aqueles com maior contribuição para o modelo e compreender como sua combinação se relaciona aos padrões espaciais do fogo (Chicas; Nielsen, 2022; Tonbul; Veraverbeke, 2026). Além disso, a utilização de projeções climáticas como dados de entrada permite estimar a distribuição espacial da probabilidade de ocorrência de incêndios

em cenários futuros (Santana *et al.*, 2024). Na Amazônia brasileira, modelos de máxima entropia já foram aplicados para estimar a probabilidade de fogo em escala regional (Fonseca *et al.*, 2016, 2019) e em estados do norte do bioma (Santana; Vasconcelos; Mariano-Neto, 2023; Santana *et al.*, 2024), mas ainda não há avaliação específica para o Pará que combine a série de cicatrizes de fogo do MapBiomas, preditores de uso da terra e projeções climáticas de modelos da sexta fase do Projeto de Intercomparação de Modelos Acoplados (CMIP6). O Pará é o segundo maior estado do país e, com Mato Grosso e Maranhão, concentra quase metade da área queimada do Brasil entre 1985 e 2024 (MapBiomas, 2025b), o que torna essa lacuna relevante para o planejamento da prevenção.

Diante desse cenário, este estudo tem como objetivo analisar a probabilidade de ocorrência de incêndios no estado do Pará e projetar possíveis alterações sob diferentes cenários climáticos futuros. Para isso, foram definidos os objetivos específicos a seguir.

1.1 OBJETIVOS ESPECÍFICOS

a) selecionar, entre variáveis bioclimáticas, de uso e cobertura da terra e de influência humana, um conjunto de preditores não colineares e quantificar a contribuição relativa de cada um para a probabilidade de ocorrência de fogo no cenário de referência;
b) mapear a distribuição espacial das classes de probabilidade de ocorrência de fogo no cenário de referência e analisar sua relação com as classes de uso e cobertura da terra e com as unidades de conservação do estado;
c) projetar a probabilidade de ocorrência de fogo para o período de 2021–2040 com os modelos climáticos MIROC6 e HadGEM3-GC31-LL, sob os cenários SSP1-2.6 e SSP5-8.5, e comparar as mudanças de área por classe em relação ao cenário de referência;
d) identificar as áreas de persistência, ganho e perda de adequabilidade ao fogo e discutir suas implicações para a prevenção e a gestão do fogo no Pará.

2 REFERENCIAL TEÓRICO

2.1 FOGO E SUA RELAÇÃO COM OS ECOSSISTEMAS

O fogo constitui um componente importante da dinâmica dos ecossistemas brasileiros, mas seus efeitos variam entre os biomas. Essa distinção é particularmente relevante para o estado do Pará, que abrange áreas dos biomas Amazônia e Cerrado. Enquanto o Cerrado apresenta uma longa história evolutiva associada ao fogo, com espécies e formações vegetais que apresentam adaptações a esse distúrbio (Jesus *et al.*, 2020; Arruda *et al.*, 2024; Salomão *et al.*, 2024), a Amazônia apresenta maior

sensibilidade a esse tipo de perturbação, uma vez que muitas de suas formações florestais não possuem adaptações a incêndios recorrentes. Essa diferença também se manifesta dentro do próprio bioma amazônico, onde enclaves de savana apresentam regimes de fogo mais frequentes do que as florestas que os circundam (Alves; Pérez-Cabello, 2017). Assim, o fogo não deve ser interpretado de maneira homogênea no território, pois seu significado ecológico e sua resposta às condições ambientais dependem das características do ecossistema e do regime de fogo ao qual está submetido.

Nesse contexto, os ecossistemas podem ser classificados, entre outras categorias, como *fire-sensitive*, *fire-dependent* ou *fire-influenced* (Hardesty; Myers; Fulks, 2005). Os ambientes *fire-sensitive* apresentam baixa tolerância à queima, enquanto ambientes *fire-dependent* ou *fire-influenced* possuem uma relação ecológica mais estreita com determinados regimes de fogo, incluindo espécies e formações vegetais adaptadas à sua ocorrência (Hardesty; Myers; Fulks, 2005). Na Amazônia, é igualmente necessário distinguir os tipos de fogo que compõem as cicatrizes observadas por sensoriamento remoto: queimadas de desmatamento, queimadas de manejo de pastagens e áreas agrícolas, e incêndios de sub-bosque em florestas em pé, que diferem em causas, intensidade e consequências ecológicas (Barlow *et al.*, 2020). Modelos de probabilidade de ocorrência baseados em cicatrizes integram esses tipos e devem ser interpretados como estimativas da propensão ambiental ao fogo, e não de um único processo.

2.2 FATORES AMBIENTAIS E ANTRÓPICOS ASSOCIADOS À OCORRÊNCIA DE INCÊNDIOS

A ocorrência e a propagação dos incêndios resultam da interação entre condições climáticas, características da vegetação e fatores relacionados à ocupação e ao uso da terra (Xu *et al.*, 2025). Entre as variáveis ambientais, a precipitação, a temperatura e a disponibilidade de umidade influenciam a secagem da vegetação e dos materiais combustíveis, alterando as condições de ignição e propagação do fogo (Flannigan *et al.*, 2016; Jones *et al.*, 2022). Períodos prolongados de estiagem, associados a temperaturas elevadas e à redução da umidade, podem ampliar a suscetibilidade dos ambientes ao fogo (IPCC, 2021). Em escala global, contudo, a ocupação humana altera os regimes de fogo tanto por acrescentar ignições quanto por fragmentar e remover combustível, de modo que o efeito líquido do clima só pode ser interpretado em conjunto com o controle antrópico (Kelley *et al.*, 2019).

Na Amazônia, o avanço do desmatamento intensifica a fragmentação florestal e favorece o ressecamento do microclima nas bordas da floresta. Essas condições aumentam a mortalidade das árvores e a disponibilidade de material combustível, tornando a vegetação mais suscetível ao fogo (Cochrane, 2001; Silva Junior *et al.*, 2018). A interação entre seca severa e fragmentação da paisagem configura um novo regime de fogo florestal, no qual incêndios de sub-bosque atingem áreas maiores

e mais distantes das bordas em anos secos (Alencar *et al.*, 2015), e a combinação de seca e fogo produz aumentos abruptos da mortalidade de árvores (Brando *et al.*, 2014). Além disso, incêndios anteriores podem alterar o microclima e a disponibilidade de material combustível, favorecendo a recorrência do fogo. Esse processo é agravado durante períodos de seca (Dutra *et al.*, 2026), quando a redução da umidade da vegetação aumenta sua inflamabilidade. As anomalias de precipitação associadas a fenômenos climáticos, como o El Niño e a Oscilação Multidecadal do Atlântico, também contribuem para a intensificação dos incêndios florestais na região (Brando *et al.*, 2019). A seca, entretanto, não explica sozinha a severidade das temporadas de fogo: ao longo do século XXI, a relação entre secas e área queimada na Amazônia brasileira não se intensificou de forma consistente (Libonati *et al.*, 2021), e a crise de 2019 ocorreu sob condições meteorológicas que, isoladamente, explicariam muito menos fogo do que o observado, apontando para o papel decisivo do uso da terra (Kelley *et al.*, 2021).

Por outro lado, os incêndios provocam alterações na estrutura e na composição florística das florestas, cuja recuperação pode exigir décadas ou séculos (Nepstad *et al.*, 2004). Além dos danos à vegetação, as emissões de CO_2 provenientes dos incêndios, somadas àquelas decorrentes do desmatamento na Amazônia, comprometem a capacidade das florestas primárias e secundárias de atuar como sumidouros de carbono, contribuindo para a intensificação das mudanças climáticas globais (Silva *et al.*, 2018). Durante períodos de seca extrema, as emissões de CO_2 associadas aos incêndios florestais podem superar aquelas provenientes do desmatamento (Campanharo *et al.*, 2019). Em 2023, mesmo com a queda do desmatamento, os incêndios em florestas maduras aumentaram expressivamente (Mataveli *et al.*, 2024).

Os impactos dos incêndios também se estendem à esfera socioeconômica. A propagação descontrolada do fogo pode ocasionar prejuízos financeiros aos produtores rurais, em decorrência da destruição de lavouras, cercas e infraestruturas residenciais (Pinho *et al.*, 2025). Ademais, a exposição à fumaça durante a temporada de queimadas pode agravar problemas respiratórios e aumentar a demanda por serviços hospitalares, ampliando os gastos públicos com assistência à saúde (Smith *et al.*, 2014; Machado-Silva *et al.*, 2020).

No que respeita à distribuição espacial das ignições, as atividades agropecuárias, a abertura de áreas, a proximidade de áreas antropizadas e a expansão da ocupação territorial constituem fatores relevantes (Ribeiro *et al.*, 2024; Zhang *et al.*, 2026). Em florestas tropicais, a combinação entre fontes de ignição de origem humana e condições climáticas favoráveis à combustão intensifica a ocorrência de incêndios e amplia seus efeitos sobre a vegetação. Assim, a interação entre seca, uso da terra e pressões antrópicas é fundamental para compreender a dinâmica do fogo na Amazônia (Nepstad *et al.*, 2004; Le Page *et al.*, 2017).

2.3 MODELAGEM DA PROBABILIDADE DE OCORRÊNCIA DE FOGO E PROJEÇÕES CLIMÁTICAS

O método de máxima entropia (MaxEnt) foi desenvolvido para estimar distribuições geográficas a partir de dados de presença apenas, contrastando as condições ambientais dos locais de ocorrência com as de pontos de fundo amostrados na área de estudo (Phillips; Anderson; Schapire, 2006; Elith *et al.*, 2011). Sua saída é uma adequabilidade relativa, e o desempenho e a transferibilidade dependem da seleção dos preditores, dos pontos de fundo, das classes de *features* e do multiplicador de regularização (Merow; Smith; Silander, 2013; Radosavljevic; Anderson, 2014). Em modelagem do fogo, o MaxEnt tem sido usado para descrever os controles ambientais da distribuição dos incêndios em múltiplas escalas (Parisien; Moritz, 2009) e, na Amazônia, para estimar a probabilidade de fogo no presente e sob cenários de clima e de uso da terra (Fonseca *et al.*, 2016, 2019; Santana; Vasconcelos; Mariano-Neto, 2023; Santana *et al.*, 2024), com aplicações semelhantes na Caatinga (Vasconcelos *et al.*, 2024) e em outras regiões propensas ao fogo (Goltas, 2026).

A avaliação desses modelos costuma apoiar-se na área sob a curva ROC (AUC), medida independente de limiar que expressa a capacidade de discriminar presenças de pontos de fundo. A AUC, porém, é sensível à extensão da área de estudo, não informa a calibração das probabilidades e é inflada por autocorrelação espacial entre treino e teste, devendo ser complementada por métricas dependentes de limiar, como a estatística de habilidade verdadeira (TSS) (Allouche; Tsoar; Kadmon, 2006; Lobo; Jiménez-Valverde; Real, 2008; Roberts *et al.*, 2017). O viés de amostragem dos pontos de presença, frequente em dados derivados de sensoriamento remoto, pode ser atenuado por filtragem espacial com distância mínima entre pontos (Boria *et al.*, 2014).

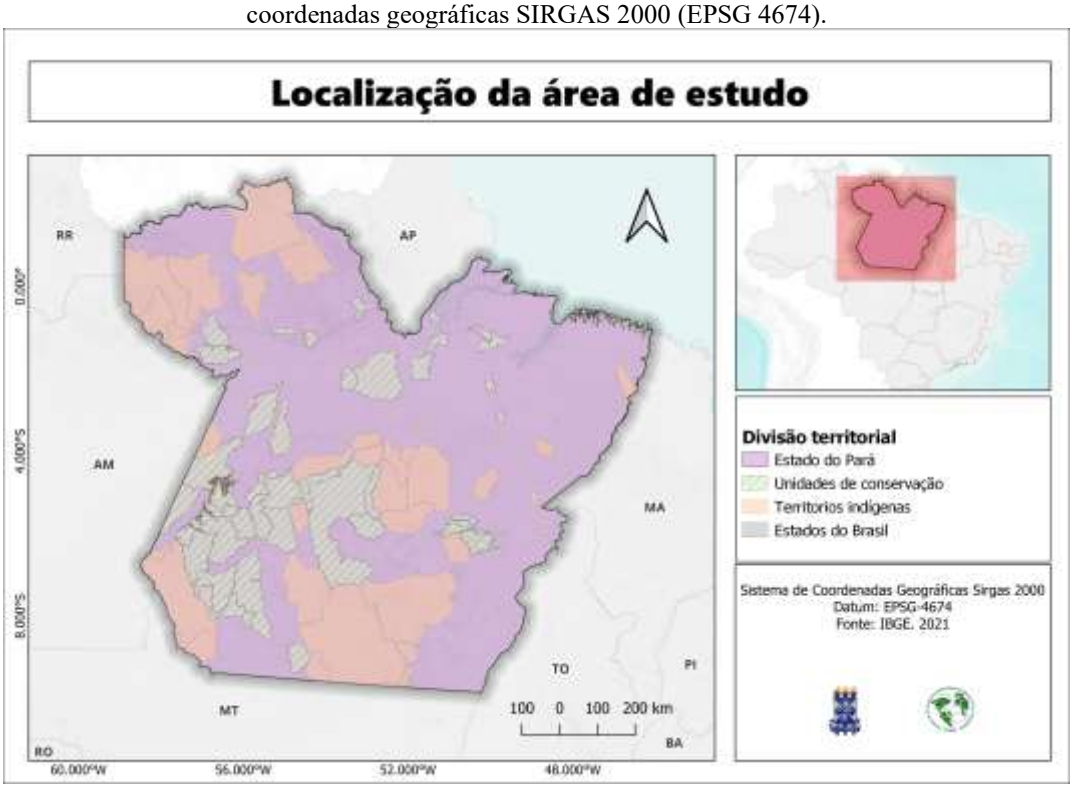
As projeções para cenários futuros utilizam saídas de modelos climáticos globais (GCMs) do CMIP6, forçadas por trajetórias socioeconômicas compartilhadas (SSPs) que combinam narrativas de desenvolvimento com níveis de forçamento radiativo (O'Neill *et al.*, 2014, 2016; Tebaldi *et al.*, 2021). A incerteza dessas projeções decompõe-se em três componentes — cenário, modelo e variabilidade interna — cujos pesos relativos variam com o horizonte temporal: nas primeiras décadas, as diferenças entre cenários são pequenas e a incerteza é dominada pelas diferenças entre modelos e pela variabilidade interna, enquanto a incerteza de cenário só se torna dominante na segunda metade do século (Hawkins; Sutton, 2009; Lehner *et al.*, 2020). Como a sensibilidade climática difere entre os GCMs, recomenda-se usar mais de um modelo; além disso, a transferência para o futuro assume relações estáveis entre fogo e preditores e, quando o uso da terra é mantido fixo, uma paisagem inalterada (Fonseca *et al.*, 2019; Whaley *et al.*, 2026).

3 METODOLOGIA

3.1 ÁREA DE ESTUDO

O estado do Pará está localizado na região Norte do Brasil, e possui uma extensão territorial de aproximadamente 1.245.831,512 km², distribuída em 144 municípios, sendo o segundo maior estado do país (IBGE, 2025) (Figura 1). De acordo com a classificação climática de Köppen-Geiger (Kottek *et al.*, 2006), predomina o clima tropical chuvoso (A), caracterizado por temperaturas médias anuais superiores a 18 °C e pela alternância entre uma estação chuvosa e outra seca, conhecidas regionalmente como inverno e verão amazônicos (Moraes *et al.*, 2005).

Figura 1. Localização do estado do Pará, com os limites das unidades de conservação e das terras indígenas. Sistema de coordenadas geográficas SIRGAS 2000 (EPSG 4674).



Fonte: Elaborado pelos próprios autores, a partir de dados do IBGE (2025), do Cadastro Nacional de Unidades de Conservação (Brasil, 2026) e da FUNAI (2026).

O território paraense abrange predominantemente o bioma Amazônia, além de áreas de Cerrado na porção sudeste. O estado também possui expressiva extensão de áreas destinadas à conservação ambiental e à proteção de territórios tradicionalmente ocupados. Foram identificadas 98 unidades de conservação, das quais 30 são de Proteção Integral e 68 de Uso Sustentável (Brasil, 2026), além de Terras Indígenas distribuídas pelo território (FUNAI, 2026). A distribuição dessas áreas, em conjunto com os padrões de uso e cobertura da terra e a ocorrência de focos de incêndio, contribui para a caracterização da heterogeneidade espacial do estado.

3.2 DADOS DE PRESENÇA DE FOGO

Os pontos de presença foram obtidos a partir dos dados do MapBiomas, que fornece informações referentes à ocorrência de cicatrizes de fogo. As cicatrizes do MapBiomas Fogo são mapeadas anualmente a partir de imagens Landsat (30 m) por meio de classificação com redes neurais profundas (Alencar *et al.*, 2022; MapBiomas, 2025b). Foram selecionados aleatoriamente 1.000 pontos nas áreas com registro de cicatrizes de fogo no período de 1985-2025, adotando-se uma distância mínima de 2.000 m entre os pontos, de modo a reduzir a dependência espacial entre as ocorrências. Esse tipo de filtragem espacial reduz o viés de amostragem e a autocorrelação entre presenças, melhorando a transferibilidade de modelos de nicho (Boria *et al.*, 2014). O número de pontos e a distância mínima foram definidos com base em testes preliminares, nos quais diferentes combinações desses parâmetros foram avaliadas, buscando identificar a configuração que proporciona melhor desempenho do modelo. Os pontos representam, portanto, a ocorrência de fogo em sentido amplo, integrando queimadas de desmatamento, de manejo e incêndios florestais (Barlow *et al.*, 2020).

3.3 VARIÁVEIS PREDITORAS (AMBIENTAIS E HUMANAS)

A seleção dos preditores foi baseada em evidências da literatura científica recente sobre a ocorrência e a distribuição espacial de incêndios em áreas amazônicas (Santana; Vasconcelos; Mariano-Neto, 2023; Santana *et al.*, 2024). Com base nessa abordagem, foram utilizados três grupos de variáveis preditoras: (i) variáveis relacionadas ao uso e à cobertura da terra; (ii) variáveis associadas à influência humana e (iii) variáveis bioclimáticas (Quadro 1).

Os dados de uso e cobertura da terra foram obtidos da Coleção 10 do projeto MapBiomas, com resolução espacial de 30 m, produzida a partir da série Landsat por classificação supervisionada no Google Earth Engine (Souza *et al.*, 2020; MapBiomas, 2025a). Posteriormente, esses dados foram reclassificados em cinco classes: floresta, agropecuária, formação natural não florestal, áreas não vegetadas e corpos d'água, de maneira a criar uma camada categórica abrangente que permitiu avaliar os impactos e a influência da paisagem nos padrões de incêndio. O ano de referência da camada de uso e cobertura não foi informado; o nome da camada utilizada na modelagem (Figura 2) indica o uso do mapa mais recente da coleção.

Para representar a influência humana, foram calculadas distâncias euclidianas às diferentes classes de uso e cobertura da terra, com o objetivo de avaliar a relação entre a proximidade dessas classes e os padrões espaciais de incêndios. Para isso, foram geradas camadas *raster* correspondentes às classes de agropecuária, corpos d'água, áreas não vegetadas e áreas urbanizadas, fortemente

associados às atividades humanas, enquanto a distância às áreas de vegetação foi utilizada como indicador de ambientes com menor influência antrópica.

Foram incorporadas à modelagem variáveis bioclimáticas, representativas das condições climáticas históricas e das projeções futuras, obtidas na base WorldClim versão 2.1 (Fick; Hijmans, 2017), com resolução espacial de 30 segundos de arco. O modelo linha de base utilizou dados médios correspondentes ao período de 1970–2000. Para as projeções futuras, foram considerados os modelos climáticos globais MIROC6 e HadGEM3-GC31-LL, selecionados com base em sua capacidade de representar padrões climáticos relevantes para a região amazônica. Esses modelos também têm apresentado desempenho satisfatório em estudos realizados em regiões tropicais e semiáridas, caracterizadas por elevada variabilidade sazonal (Dantas *et al.*, 2022; Vasconcelos *et al.*, 2024). Apesar de ambos os modelos serem utilizados para representar possíveis condições climáticas futuras, eles diferem quanto à Sensibilidade Climática de Equilíbrio (ECS): o HadGEM3-GC31-LL situa-se no extremo superior do conjunto CMIP6, com ECS de cerca de 5,5 °C (Andrews *et al.*, 2019), enquanto o MIROC6 apresenta ECS de cerca de 2,6 °C (Tatebe *et al.*, 2019), próxima ao limite inferior da faixa de 1,8 °C a 5,6 °C dos modelos dessa geração (Meehl *et al.*, 2020). A utilização conjunta desses modelos permite considerar diferentes respostas do sistema climático às forças radiativas e, consequentemente, ampliar a representação das possíveis condições climáticas futuras na área de estudo. As superfícies futuras do WorldClim correspondem às saídas dos GCMs reduzidas de escala e calibradas em relação à climatologia de referência de 1970–2000 (Fick; Hijmans, 2017).

As projeções futuras para o período de 2021-2040 foram desenvolvidas utilizando dois cenários distintos, baseados em trajetórias socioeconômicas compartilhadas (O'Neill *et al.*, 2014, 2016). O primeiro cenário, SSP1-2.6, representa um futuro de baixas emissões, com forçamento radiativo de 2,6 W m^{-2} em 2100, e o segundo, SSP5-8.5, um futuro de altas emissões, com forçamento de 8,5 W m^{-2}. As melhores estimativas de aquecimento global para 2081–2100 em relação a 1850–1900 são de 1,8 °C no SSP1-2.6 e de 4,4 °C no SSP5-8.5 (IPCC, 2021), embora a plausibilidade do SSP5-8.5 como trajetória de emissões tenha sido questionada (Pielke Jr; Burgess; Ritchie, 2022). No horizonte 2021–2040, contudo, as diferenças de aquecimento entre os cenários são da ordem de décimos de grau (IPCC, 2021), de modo que as divergências entre as projeções deste estudo devem refletir, sobretudo, diferenças entre os modelos climáticos e a variabilidade interna de cada simulação (Hawkins; Sutton, 2009; Lehner *et al.*, 2020).

Quadro 1. Variáveis candidatas utilizadas na modelagem da probabilidade de ocorrência de incêndios no estado do Pará.

Grupo	Variáveis	Resolução e tipo	Fonte
Bioclimáticas – temperatura	BIO1 temperatura média anual; BIO2 amplitude diurna média; BIO3 isotermalidade; BIO4 sazonalidade da temperatura; BIO5 máxima do mês mais quente; BIO6 mínima do mês mais frio; BIO7 amplitude térmica anual (BIO5 − BIO6); BIO8 a BIO11 temperatura média dos trimestres mais úmido, mais seco, mais quente e mais frio	30 segundos de arco (≈ 1 km); contínuo	WorldClim 2.1 – Fick; Hijmans (2017)
Bioclimáticas – precipitação	BIO12 precipitação anual; BIO13 e BIO14 precipitação dos meses mais úmido e mais seco; BIO15 sazonalidade da precipitação; BIO16 a BIO19 precipitação dos trimestres mais úmido, mais seco, mais quente e mais frio		
Uso e cobertura da terra	LULC reclassificado em cinco classes	30 m; categórico	MapBiomas – Coleção 10 (Souza *et al.*, 2020; MapBiomas, 2025a)
Influência humana	Distâncias euclidianas à agropecuária, a áreas não vegetadas, a áreas urbanizadas, à vegetação e a corpos d'água	30 m; contínuo	

Fonte: Elaborado pelos próprios autores.

3.4 SELEÇÃO DE VARIÁVEIS

Inicialmente, todas as camadas foram reamostradas para a mesma resolução espacial dos dados bioclimáticos (30 segundos de arco, aproximadamente 1 km), garantindo a compatibilidade espacial entre os conjuntos de dados. Em seguida, foi realizada a seleção das variáveis preditoras para a construção do modelo de linha de base, utilizando o pacote SDMtune, versão 1.3.1, que contém funções para a seleção de variáveis e o ajuste de hiperparâmetros, reduzindo o tempo necessário para encontrar uma configuração adequada do modelo (Vignali *et al.*, 2020).

A seleção das variáveis foi realizada por meio da função *varSel()*, com base na correlação de *Spearman*. Adotou-se um limiar de $|\rho| \geq 0{,}7$ para identificar e reduzir a multicolinearidade entre os preditores. Adicionalmente, foram realizadas 1.000 permutações para avaliar a importância dos preditores e obter estimativas mais robustas de sua contribuição para o desempenho do modelo.

Como etapa complementar, foi realizada a análise de *Jackknife*, utilizando a AUC como métrica de desempenho, com o objetivo de quantificar a contribuição individual das variáveis selecionadas. Esse procedimento resultou em um conjunto mais reduzido de variáveis, minimizando a redundância e mantendo aquelas com maior contribuição para o modelo. Das 25 variáveis candidatas (Quadro 1),

12 foram retidas no modelo final: sete bioclimáticas (BIO4, BIO7, BIO8, BIO13, BIO15, BIO18 e BIO19), o uso e cobertura da terra e as distâncias à agropecuária, a áreas não vegetadas, à vegetação e a corpos d'água; a distância a áreas urbanizadas não permaneceu no conjunto final.

3.5 MODELAGEM MAXENT, AVALIAÇÃO E PROJEÇÕES

As probabilidades de ocorrência ao fogo foram modeladas com base no método de Máxima Entropia (MaxEnt), um algoritmo de aprendizado de máquina baseado em funções de só presença que contrasta iterativamente vários valores preditores em locais de ocorrência com aqueles de locais aleatórios na área de estudo (Phillips; Anderson; Schapire, 2006; Elith *et al.*, 2011). Essa abordagem é particularmente útil em situações nas quais é difícil obter dados confiáveis de ausência. Estudos anteriores têm empregado essa metodologia na modelagem espacial de incêndios, demonstrando sua aplicabilidade na estimativa da propensão à ocorrência de fogo em diferentes contextos ambientais (Parisien; Moritz, 2009; Fonseca *et al.*, 2016; Goltas, 2026).

O conjunto de dados foi dividido em duas partições, 70% para dados de treinamento e 30% para dados de teste. Independente destes pontos foram utilizados backgrounds (pontos de fundo), no caso foram aplicados 2.000 pontos de fundo para os dados de treinamento e 600 para os de teste, além de um multiplicador de regularização de 0,5. A capacidade preditiva dos modelos foi mensurada a partir da área sob a curva (AUC), métrica utilizada para verificar o ajuste e capacidade do modelo de prever ocorrências de fogo. A AUC é considerada uma medida de desempenho independente do limiar amplamente utilizada para quantificar a precisão das previsões espaciais, com valores que variam de 0,5 (uma previsão aleatória) a 1 (uma excelente previsão) (Phillips; Anderson; Schapire, 2006), e foi interpretada segundo a classificação de Yesilnacar e Topal (2005), em que valores entre 0,9 e 1,0 correspondem a desempenho excelente. Métricas dependentes de limiar, como a TSS (Allouche; Tsoar; Kadmon, 2006), não foram calculadas. O número de réplicas do ajuste, as classes de *features* empregadas e o tipo de saída do MaxEnt (logística ou *cloglog*) não foram registrados pelos autores e constituem uma limitação à reprodutibilidade discutida na seção 4.5.

Para a otimização dos modelos, utilizou-se a função *optimizeModel*, disponível no pacote SDMtune, que emprega um algoritmo genético para identificar, de forma iterativa, a combinação de hiperparâmetros associada ao melhor desempenho do modelo. O processo envolve a geração e avaliação de diferentes configurações com base em uma métrica de desempenho calculada no conjunto de validação, seguida de etapas de seleção, cruzamento e mutação das configurações mais promissoras ao longo de sucessivas gerações (Vignali *et al.*, 2020). Ao final desse processo, o modelo otimizado é utilizado na construção do modelo final, posteriormente empregado para realizar as projeções sob os

cenários climáticos futuros. Os valores finais dos hiperparâmetros selecionados pelo algoritmo genético não foram informados. Nas projeções, as camadas de uso e cobertura da terra e de distâncias foram mantidas fixas, de modo que as diferenças entre o cenário de referência e os cenários futuros decorrem exclusivamente da substituição das variáveis bioclimáticas pelas superfícies projetadas de cada GCM e SSP.

As análises espaciais foram realizadas com base na classificação dos valores de probabilidade estimados pelo modelo em cinco níveis de risco de incêndio: muito baixo, baixo, moderado, alto e muito alto. Para a representação, os pixels foram agrupados nos seguintes intervalos de probabilidade: muito baixo ($0{,}00 \leq x < 0{,}10$), baixo ($0{,}10 \leq x < 0{,}30$), moderado ($0{,}30 \leq x < 0{,}50$), alto ($0{,}50 \leq x < 0{,}75$) e muito alto ($0{,}75 \leq x \leq 1{,}00$). A área de cada classe foi quantificada para o cenário de referência e para cada combinação de GCM e SSP, e as mudanças entre cenários foram expressas em pontos percentuais da área do estado. Adicionalmente, as superfícies de referência e futuras foram binarizadas em áreas adequadas e inadequadas ao fogo e sobrepostas para identificar quatro situações: inadequabilidade persistente, adequabilidade persistente, ganho e perda de adequabilidade. O limiar de binarização utilizado nessa etapa não foi informado pelos autores. Por fim, as classes de probabilidade do cenário de referência foram cruzadas com as classes de uso e cobertura da terra e com os limites das unidades de conservação.

4 RESULTADOS E DISCUSSÃO

4.1 DESEMPENHO DOS MODELOS

O modelo de referência apresentou valor médio de AUC 0,909 no conjunto de teste. No período de 2021–2040, os valores de AUC permaneceram na faixa considerada excelente, variando de 0,903 a 0,921 entre os modelos climáticos e cenários avaliados. O MIROC6 apresentou AUC de 0,904 no cenário otimista e 0,921 no pessimista, enquanto o HadGEM3-GC31-LL registrou 0,904 e 0,903, respectivamente. Segundo a classificação proposta por Yesilnacar e Topal (2005), valores entre 0,9 e 1,0 correspondem a desempenho excelente, evidenciando a elevada capacidade dos modelos em discriminar a probabilidade de ocorrência de incêndios.

Esses valores devem ser interpretados com cautela. A AUC do modelo de referência tende a ser inflada em áreas extensas e heterogêneas, como o Pará, e quando teste e treino são espacialmente próximos (Lobo; Jiménez-Valverde; Real, 2008; Roberts *et al.*, 2017). Além disso, não existem registros de ocorrência para 2021–2040; os valores de AUC associados aos cenários futuros não constituem, portanto, validação das projeções, e sim uma medida de consistência entre as superfícies projetadas e os pontos de teste do período de referência. O procedimento exato de cálculo desses

valores não foi detalhado, o que é registrado como pendência metodológica. Os valores de AUC obtidos são semelhantes aos reportados para modelos MaxEnt de fogo na Amazônia (Fonseca *et al.*, 2016; Santana; Vasconcelos; Mariano-Neto, 2023; Santana *et al.*, 2024).

4.2 IMPORTÂNCIA DAS VARIÁVEIS E CURVAS DE RESPOSTA

A análise da importância de permutação das variáveis indicou que os fatores associados à influência antrópica são decisivos na probabilidade de ocorrência de incêndios. A distância às áreas agropecuárias apresentou a maior contribuição, correspondendo a 53,1% (Tabela 1). Esse resultado corrobora os achados de Santana, Vasconcelos e Mariano-Neto (2023) e pode estar relacionado ao uso do fogo no manejo de áreas agrícolas e pastagens, bem como à sua propagação para áreas de vegetação adjacentes. De forma semelhante, Cano-Crespo *et al.* (2015), ao analisarem os estados do Pará, Mato Grosso e Rondônia, identificaram uma forte associação entre a ocorrência de incêndios e os usos antrópicos da terra, sobretudo em áreas de pastagem e agricultura.

Tabela 1. Importância por permutação das variáveis retidas no modelo de probabilidade de ocorrência de incêndios para o cenário de referência.

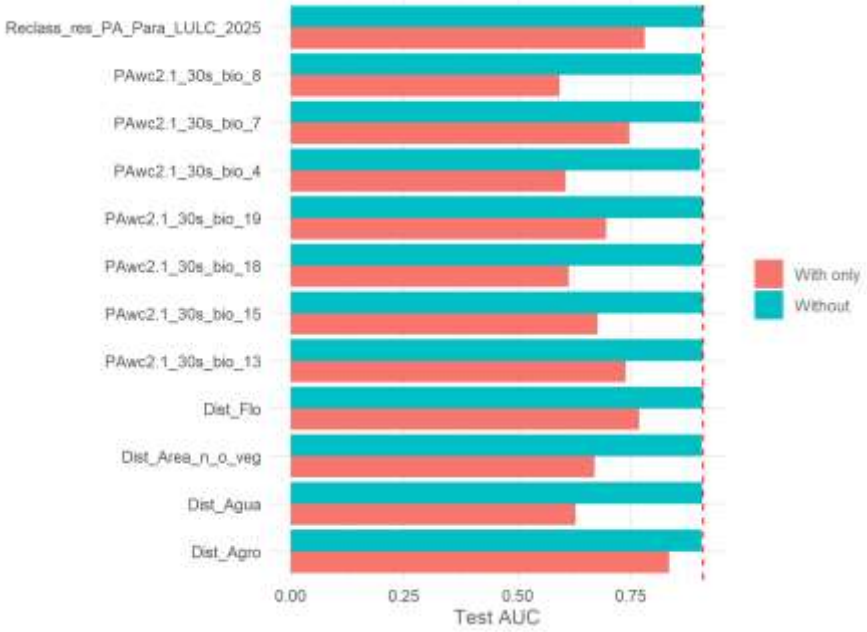
Variável (código)	Grupo	Importância por permutação (%)
Distância à agropecuária (Dist_Agro)	Influência humana	53,1
Amplitude térmica anual (BIO7)	Bioclimática	19,6
Distância a áreas não vegetadas (Dist_Area_n_o_veg)	Influência humana	7,1
Sazonalidade da temperatura (BIO4)	Bioclimática	4,7
Precipitação do trimestre mais frio (BIO19)	Bioclimática	3,6
Sazonalidade da precipitação (BIO15)	Bioclimática	3,1
Temperatura média do trimestre mais úmido (BIO8)	Bioclimática	2,9
Precipitação do mês mais úmido (BIO13)	Bioclimática	2,0
Uso e cobertura da terra (LULC)	Uso e cobertura da terra	1,7
Precipitação do trimestre mais quente (BIO18)	Bioclimática	1,1
Distância a corpos d'água (Dist_Agua)	Influência humana	1,0
Distância à vegetação (Dist_Flo)	Influência humana	0,1

Fonte: Elaborada pelos autores

A variação anual da temperatura foi a segunda variável de maior contribuição, com 19,6%, em concordância com Vasconcelos *et al.* (2024), que identificaram os fatores relacionados à temperatura como os principais determinantes da ocorrência de incêndios. A distância às áreas não vegetadas também se destacou, com contribuição de 7,1%, reforçando a associação entre a dinâmica do fogo e as alterações no uso e cobertura da terra. Entre as variáveis climáticas, a sazonalidade da temperatura contribuiu com 4,7%, enquanto a precipitação do trimestre mais frio e a sazonalidade da precipitação apresentaram contribuições de 3,6% e 3,1%, respectivamente (Tabela 1).

O teste Jackknife destacou o desempenho preditivo das variáveis antrópicas, com destaque para a distância às áreas agropecuárias, que apresentou o maior AUC, seguida pela variável de uso e cobertura da terra (Figura 2). Entre os fatores climáticos, a amplitude térmica anual apresentou capacidade preditiva relevante, evidenciando a contribuição das condições térmicas para a distribuição espacial dos incêndios. A exclusão de qualquer variável isolada reduz pouco a AUC do modelo completo (Figura 2), o que indica redundância parcial entre os preditores retidos.

Figura 2. Teste jackknife da AUC de teste para as 12 variáveis retidas no modelo de referência: barras vermelhas indicam o modelo ajustado apenas com a variável (with only) e barras azuis, o modelo sem a variável (without); a linha tracejada indica a AUC do modelo completo. Códigos das camadas: Dist_Agro = distância à agropecuária; Dist_Agua = distância a corpos d'água; Dist_Area_n_o_veg = distância a áreas não vegetadas; Dist_Flo = distância à vegetação; PAwc2.1_30s_bio_N = variável bioclimática BIO N do WorldClim 2.1; Reclass_res_PA_Para_LULC_2025 = uso e cobertura da terra reclassificado.



Fonte: Elaborado pelos próprios autores.

As curvas de resposta das cinco variáveis de maior influência evidenciaram diferentes padrões. A distância às áreas agropecuárias apresentou uma relação inversa com a probabilidade de incêndio, demonstrando maior propensão à ocorrência nas proximidades dessas áreas. Em contrapartida, a amplitude térmica anual mostra um aumento quase constante, com valores máximos em torno de 17,5 °C. A distância às áreas não vegetadas exibiu um padrão não linear, caracterizado por uma redução inicial da probabilidade, seguida de um aumento acentuado até aproximadamente 300 m e de um leve declínio em distâncias maiores. A sazonalidade da temperatura revelou uma tendência de aumento moderado, sugerindo maior probabilidade em áreas de maior variabilidade térmica sazonal. Por fim, a precipitação do trimestre mais frio demonstrou uma relação positiva com a probabilidade de incêndio,

com valores baixos para precipitações inferiores a 950 mm e aumento acentuado acima desse limiar, alcançando os níveis máximos em áreas com precipitação superior a 1.400 mm. As curvas de resposta não são apresentadas em figura neste artigo; a descrição acima baseia-se nas saídas do modelo registradas pelos autores.

A interpretação mecanicista dessas respostas exige distinguir efeitos diretos de efeitos de correlação espacial. A relação negativa com a distância à agropecuária é compatível com a origem predominantemente antrópica das ignições na Amazônia, onde raios respondem por fração muito pequena dos incêndios (Zhang *et al.*, 2026) e o fogo escapa das pastagens e áreas de abertura para as bordas florestais vizinhas (Cano-Crespo *et al.*, 2015; Alencar *et al.*, 2015). Já a resposta positiva à amplitude térmica anual e à sazonalidade da temperatura reflete, em grande parte, o gradiente climático do estado: as porções sul e sudeste, de clima mais sazonal e estação seca mais marcada, coincidem com a frente de ocupação agropecuária, de modo que essas variáveis combinam um efeito direto sobre a secagem do combustível (Flannigan *et al.*, 2016) com a assinatura espacial da fronteira agrícola. A resposta positiva à precipitação do trimestre mais frio, à primeira vista contraintuitiva, provavelmente expressa o mesmo tipo de associação espacial com o leste do estado, mais chuvoso e mais ocupado, e não um efeito causal da chuva sobre o fogo; em modelos correlativos, essas variáveis devem ser lidas como descritores de onde o fogo ocorre, e não necessariamente de por que ocorre (Parisien; Moritz, 2009; Merow; Smith; Silander, 2013).

Os resultados evidenciam a predominância das variáveis associadas às atividades antrópicas e ao uso e cobertura da terra, que correspondem a aproximadamente 63% da contribuição total, enquanto os fatores climáticos representam cerca de 37%. Essa proporção converge com análises em escala de bioma, nas quais o uso da terra e a distância às áreas antropizadas explicam a maior parte da variação espacial da atividade do fogo na Amazônia, com o clima atuando como modulador interanual (Fonseca *et al.*, 2016; Xu *et al.*, 2025), e com a evidência de que os picos recentes de fogo não são explicados apenas pelas condições meteorológicas (Kelley *et al.*, 2021). Essa predominância reforça a importância de aprimorar as práticas de manejo do solo e fortalecer as estratégias de prevenção e controle do fogo no estado do Pará, considerando a influência das atividades humanas na distribuição espacial da probabilidade de ocorrência de incêndios.

4.3 PROBABILIDADE DE OCORRÊNCIA DE FOGO NO CENÁRIO DE REFERÊNCIA

A distribuição espacial da probabilidade de ocorrência de incêndios no cenário de referência apresentou variações entre as regiões do Pará. As classes de probabilidade muito baixa e baixa abrangeram 41,2% e 28,8% da área estadual, respectivamente, enquanto as classes moderada, alta e

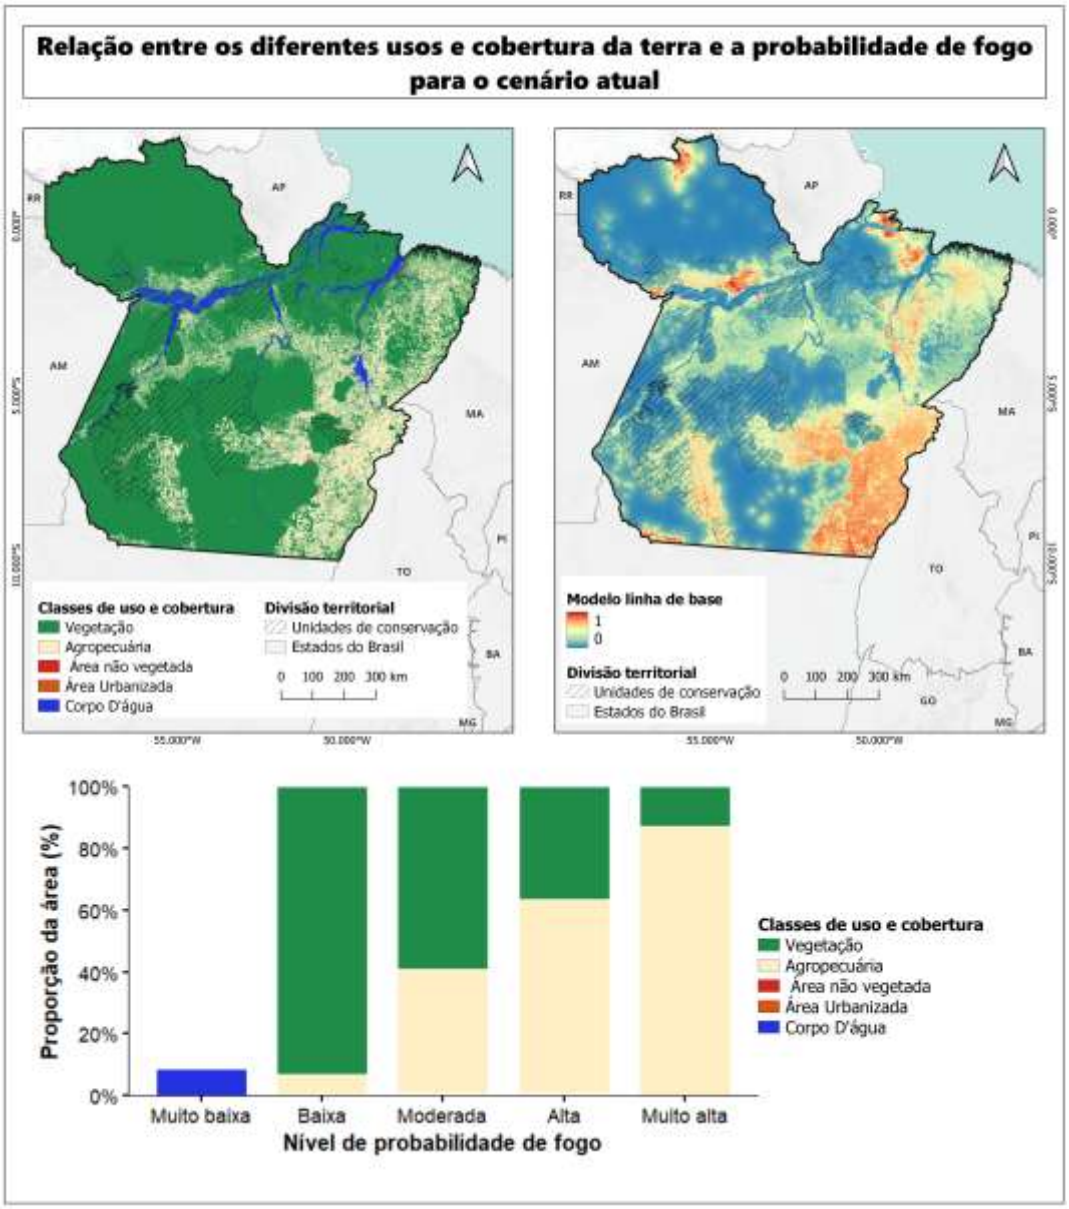
muito alta corresponderam a 13,6%, 12,0% e 4,8%. Em conjunto, as três classes de maior probabilidade representaram 30,4% do território, indicando que, embora predominem áreas com menor probabilidade estimada, uma parcela expressiva do estado apresenta condições favoráveis à ocorrência desse fenômeno. Em área, as classes correspondem a 512,5, 355,9, 168,9, 148,9 e 59,1 mil km², respectivamente (Tabela 2).

As classes muito baixa e baixa predominaram no oeste do estado, enquanto as classes alta e muito alta se concentraram nas porções sul, sudeste e leste do estado, especialmente em áreas integradas ao Arco do Desmatamento (Figura 3). Essa distribuição é consistente com os resultados de Santos *et al.* (2026), que identificaram, entre 2010 e 2017, os maiores índices de focos de calor do estado no Sudeste Paraense, sobretudo entre agosto e outubro, período correspondente à estação seca. Essa convergência reforça a relevância das pressões antrópicas e da sazonalidade climática para compreender a distribuição espacial dos incêndios no Pará.

Em relação às unidades de conservação, observou-se que a maioria está inserida em áreas com baixa ou muito baixa probabilidade de ocorrência de incêndios. Entretanto, algumas unidades, como a Reserva Biológica Nascentes da Serra do Cachimbo, abrangem setores classificados nas classes moderada a muito alta, indicando maior exposição potencial ao fogo. A presença dessas classes nas zonas limítrofes das unidades merece atenção, uma vez que a proximidade de áreas suscetíveis ao fogo pode favorecer sua propagação para o interior dos territórios protegidos. Esse cenário evidencia a importância de considerar não apenas as condições internas das unidades de conservação, mas também a dinâmica do uso da terra em seu entorno, especialmente onde há expansão agropecuária.

A relação entre as classes de probabilidade ao fogo e o uso e a cobertura da terra evidenciou uma forte participação das áreas agropecuárias (Figura 3). Nas classes de probabilidade muito baixa e baixa, a vegetação representou aproximadamente 91% da área de cada classe. Na classe moderada, por sua vez, a vegetação diminuiu, enquanto as áreas agropecuárias passaram a representar 39,81%. Essa tendência tornou-se ainda mais evidente nas classes alta e muito alta, nas quais as áreas agropecuárias corresponderam a 62,65% e 87,14%, respectivamente.

Figura 3. Uso e cobertura da terra e probabilidade de ocorrência de fogo no cenário de referência, estado do Pará: (a) classes de uso e cobertura da terra reclassificadas a partir da Coleção 10 do MapBiomas; (b) superfície contínua de probabilidade do modelo de referência (0–1), com os limites das unidades de conservação; (c) proporção da área de cada classe de probabilidade ocupada por cada classe de uso e cobertura.



Nota: no painel (c), a barra da classe "muito baixa" exibe apenas a parcela de corpos d'água; a proporção de vegetação dessa classe, referida no texto (≈ 91%), não está representada no gráfico original.
Fonte: Elaborado pelos próprios autores, a partir dos dados gerados.

Esse padrão é compatível com a dinâmica de ocupação da Amazônia, onde o uso do fogo está frequentemente associado à abertura e à manutenção de áreas destinadas à agricultura e à pecuária. Embora aproximadamente 74% do território paraense seja coberto por florestas naturais (MapBiomas, 2025a), a ocorrência de incêndios concentra-se também em áreas submetidas à expansão agropecuária, nas quais a vegetação é removida e posteriormente queimada para viabilizar novos usos da terra (White, 2018; Ribeiro *et al.*, 2021). No Pará central, Reis *et al.* (2021) mostraram que a proximidade

de desmatamentos recentes e de estradas, combinada com a seca sazonal, explica a maior parte da variação espacial e temporal dos incêndios florestais, e Ribeiro *et al.* (2024) demonstraram que a atividade do fogo é máxima nos primeiros anos após a transição de uso da terra, decaindo à medida que a paisagem se consolida.

4.4 PROJEÇÕES PARA O PERÍODO DE 2021–2040

Os modelos futuros simulados para modelos climáticos MIROC6 (Figura 4) e HadGEM3-GC31-LL (Figura 5) apresentaram padrões espaciais semelhantes aos do cenário de referência. Em ambos os modelos, observa-se a predominância das classes de propensão muito baixa e baixa. As classes moderada, alta e muito alta exibiram distribuição mais heterogênea, concentrando-se principalmente nas porções sul, sudeste e leste do estado, além de ocorrências espacialmente dispersas em outras regiões. As áreas por classe em cada combinação de modelo e cenário, extraídas dos gráficos das Figuras 4 e 5, estão reunidas na Tabela 2.

Tabela 2. Área (10^3 km²) das classes de probabilidade de ocorrência de fogo no estado do Pará no cenário de referência e nas projeções para 2021–2040, por modelo climático e cenário.

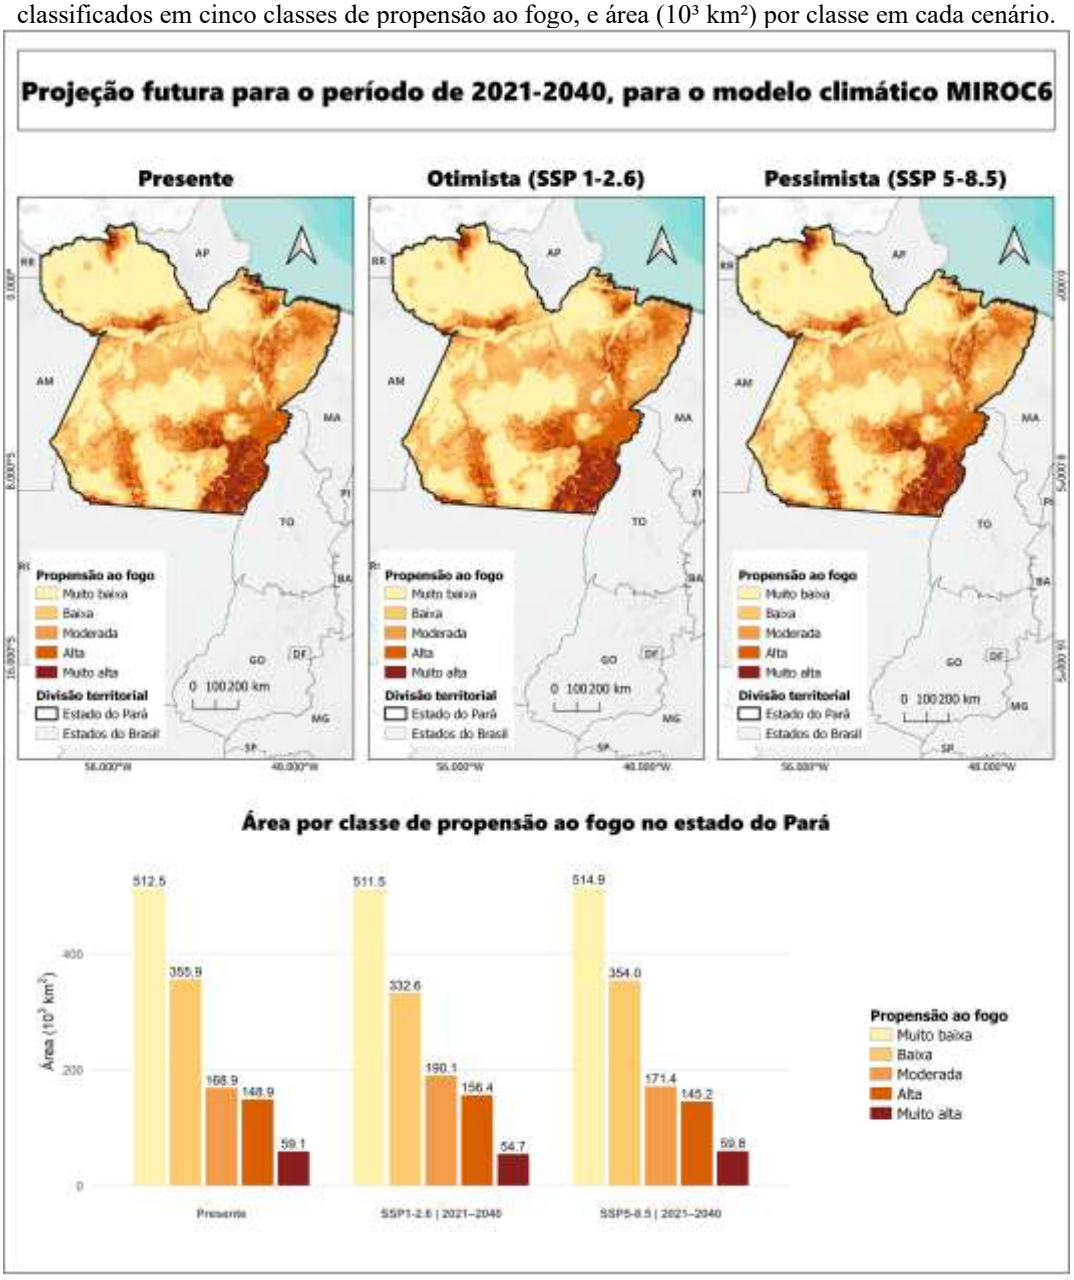
Classe de probabilidade	Referência	MIROC6 SSP1-2.6	MIROC6 SSP5-8.5	HadGEM3-GC31-LL SSP1-2.6	HadGEM3-GC31-LL SSP5-8.5
Muito baixa (0,00–0,10)	512,5	511,5	514,9	500,9	503,0
Baixa (0,10–0,30)	355,9	332,6	354,0	341,2	349,5
Moderada (0,30–0,50)	168,9	190,1	171,4	178,9	179,3
Alta (0,50–0,75)	148,9	156,4	145,2	175,3	154,6
Muito alta (0,75–1,00)	59,1	54,7	59,8	49,0	59,0
Moderada a muito alta (soma)	376,9	401,2	376,4	403,2	392,9

Fonte: Elaborado pelos próprios autores, a partir dos valores apresentados nos gráficos das Figuras 4 e 5 (área total do estado ≈ 1.245,3 mil km²).

No cenário otimista (SSP1-2.6), o MIROC6 projetou aumentos de 1,71% e 0,6% nas classes moderada e alta, respectivamente. O HadGEM3-GC31-LL também indicou aumento dessas classes, com destaque para a classe alta, cuja participação aumentou 2,12%. No cenário pessimista (SSP5-8.5), as alterações projetadas pelo MIROC6 foram mais discretas, com aumentos de 0,2% na classe moderada e de 0,06% na muito alta. Em contrapartida, o HadGEM3-GC31-LL apresentou mudanças mais expressivas, com aumentos de 0,84% e 0,45% nas classes moderada e alta, respectivamente. Esses valores correspondem a pontos percentuais da área do estado: a classe moderada, por exemplo, passa de 168,9 para 190,1 mil km² no MIROC6 SSP1-2.6, e a classe alta, de 148,9 para 175,3 mil km² no HadGEM3-GC31-LL SSP1-2.6 (Tabela 2). De modo geral, o MIROC6 apresentou maior

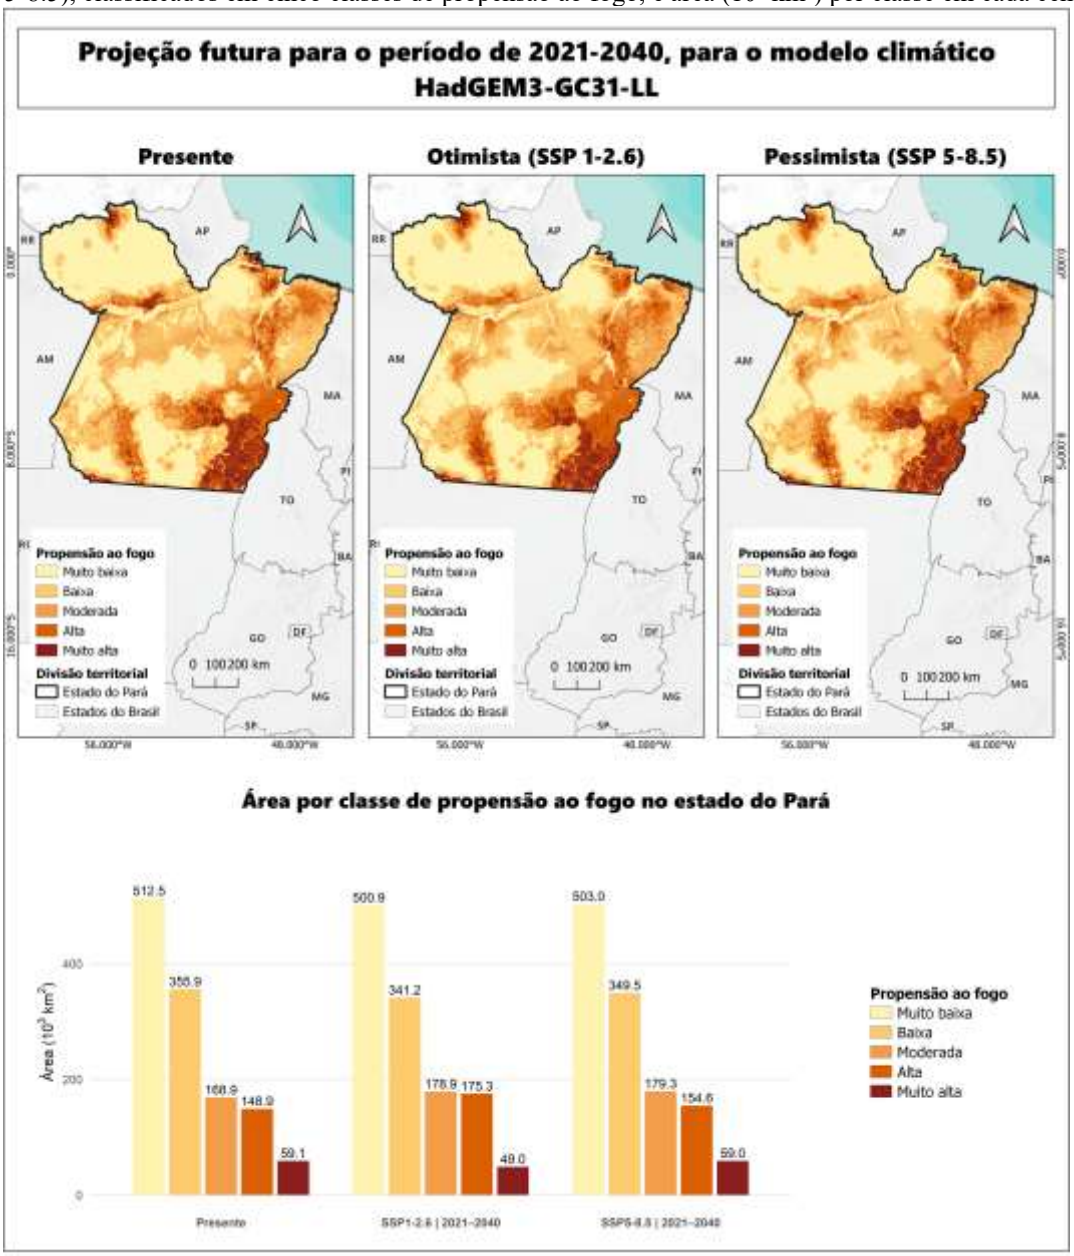
estabilidade em relação ao presente, enquanto o HadGEM3-GC31-LL evidenciou alterações mais acentuadas na distribuição das classes de probabilidade.

Figura 4. Probabilidade de ocorrência de fogo no estado do Pará projetada com o modelo climático MIROC6 para 2021–2040: mapas do cenário de referência (presente), do cenário otimista (SSP1-2.6) e do cenário pessimista (SSP5-8.5), classificados em cinco classes de propensão ao fogo, e área (10^3 km²) por classe em cada cenário.



Fonte: Elaborado pelos próprios autores, a partir dos dados gerados.

Figura 5. Probabilidade de ocorrência de fogo no estado do Pará projetada com o modelo climático HadGEM3-GC31-LL para 2021–2040: mapas do cenário de referência (presente), do cenário otimista (SSP1-2.6) e do cenário pessimista (SSP5-8.5), classificados em cinco classes de propensão ao fogo, e área (10^3 km²) por classe em cada cenário.



Fonte: Elaborado pelos próprios autores, a partir dos dados gerados.

Um aspecto que merece destaque na Tabela 2 é que, para os dois modelos climáticos, as mudanças projetadas no cenário SSP1-2.6 foram de magnitude igual ou superior às do SSP5-8.5: a soma das classes moderada a muito alta cresce 24,3 mil km² (MIROC6) e 26,3 mil km² (HadGEM3-GC31-LL) no cenário otimista, contra −0,5 e 16,0 mil km² no pessimista, e a classe muito alta diminui no SSP1-2.6 do HadGEM3-GC31-LL (de 59,1 para 49,0 mil km²). Esse comportamento não indica que menores emissões aumentem o fogo; ele é esperado para um horizonte tão próximo quanto 2021–2040, no qual os forçamentos dos dois cenários ainda são semelhantes e as diferenças entre simulações

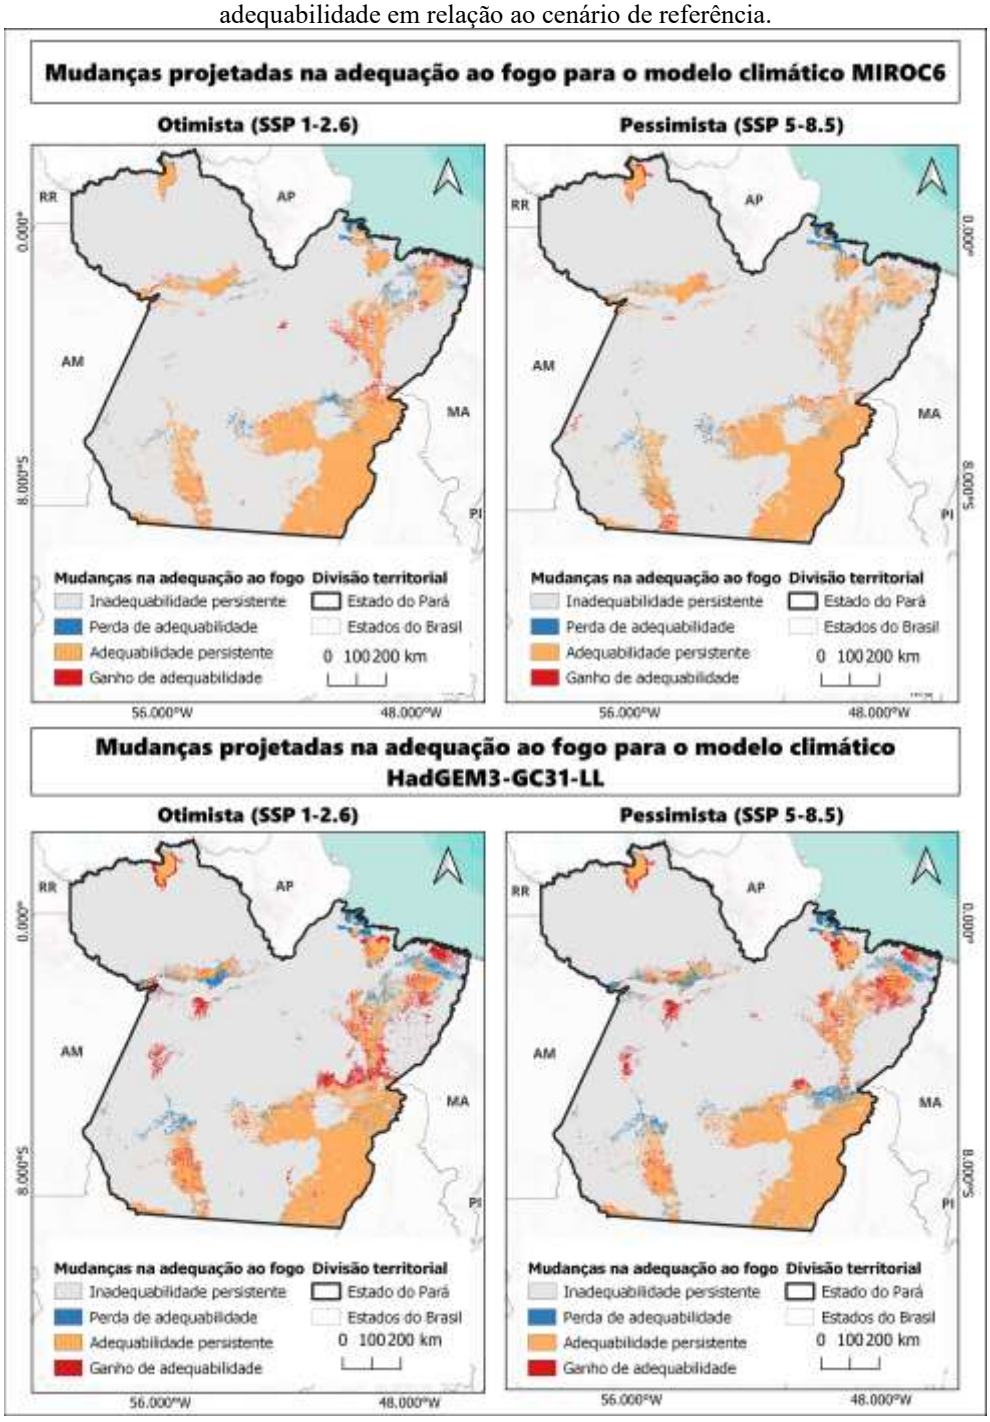
são dominadas pela variabilidade interna de cada modelo e pela forma como o padrão espacial das anomalias de temperatura e precipitação se distribui sobre o estado (Hawkins; Sutton, 2009; Lehner *et al.*, 2020; Tebaldi *et al.*, 2021). Assim, as diferenças entre cenários neste horizonte devem ser lidas como indicadores de incerteza, e não como sinal de resposta às emissões; o sinal robusto é a persistência do padrão espacial e a tendência de aumento das classes moderada e alta nas porções sul, sudeste e leste.

As diferenças evidenciam a variabilidade das projeções entre os modelos climáticos, associada às incertezas inerentes à representação do sistema climático e dos processos que condicionam a ocorrência de incêndios. Dessa forma, as respostas projetadas devem ser interpretadas considerando as particularidades dos modelos e as interações entre condições climáticas, vegetação e atividades humanas (Tebaldi *et al.*, 2021; Whaley *et al.*, 2026). A maior magnitude das mudanças no HadGEM3-GC31-LL é coerente com sua sensibilidade climática mais elevada (Andrews *et al.*, 2019; Meehl *et al.*, 2020).

Essas tendências também foram observadas na análise das mudanças de adequabilidade ao fogo. No modelo MIROC6 a adequabilidade persistente correspondeu a 22,14% no cenário otimista (SSP1-2.6) e a 22,13% no pessimista (SSP5-8.5), enquanto os ganhos de adequabilidade representaram 17,87% e 17,74%, respectivamente. O modelo HadGEM3-GC31-LL apresentou comportamento semelhante, com adequabilidade persistente de 21,85% e 21,81% e ganhos de adequabilidade de 18,49% e 18,27% nos respectivos cenários. Os percentuais de perda de adequabilidade e de inadequabilidade persistente não foram quantificados pelos autores, e o limiar utilizado para definir área adequada não foi informado, de modo que esses percentuais não são diretamente comparáveis às mudanças de área por classe da Tabela 2.

A persistência de áreas adequadas e inadequadas ao fogo (Figura 6) para cada classe evidencia que as respostas projetadas para o Pará envolvem tanto a manutenção de condições ambientais preexistentes quanto mudanças no uso e cobertura da terra. No oeste, a predominância de áreas de inadequabilidade persistente coincide com extensas áreas florestais. Dessa forma, a permanência da cobertura florestal pode contribuir para reduzir as pressões decorrentes da conversão da vegetação nativa (Souza *et al.*, 2023), mas não elimina a influência das condições climáticas nem a possibilidade de incêndios associados à ação humana (Xu *et al.*, 2025).

Figura 6. Mudanças projetadas na adequabilidade ao fogo no estado do Pará para 2021–2040, nos cenários SSP1-2.6 e SSP5-8.5: (a) modelo climático MIROC6 (painéis superiores); (b) modelo climático HadGEM3-GC31-LL (painéis inferiores). Classes: inadequabilidade persistente, perda de adequabilidade, adequabilidade persistente e ganho de adequabilidade em relação ao cenário de referência.



Fonte: Elaborado pelos próprios autores, a partir dos dados gerados.

No leste e sudeste do Pará, a presença de áreas com ganho e adequabilidade persistente ao fogo merece atenção diante da expansão agropecuária e das transformações da cobertura vegetal associadas ao Arco do Desmatamento (Martins; Francisco, 2025). De acordo com dados do MapBiomas (2025a), nos últimos dez anos, as áreas agropecuárias no estado aumentaram 23,5%, enquanto a cobertura

florestal diminuiu aproximadamente 4%. Em escala nacional, os biomas Amazônia e Cerrado concentraram, conjuntamente, cerca de 86% da área queimada no Brasil ao longo de quatro décadas, e aproximadamente 3,7 milhões de hectares apresentaram recorrência de queimadas superior a 16 vezes nesse período (MapBiomas, 2025b). Esses dados ressaltam a importância da análise conjunta da extensão e da recorrência do fogo em regiões submetidas a intensas transformações ambientais.

A conversão da vegetação nativa em pastagens e áreas agrícolas pode favorecer essa dinâmica por meio do aumento das fontes de ignição, da fragmentação dos remanescentes florestais e das alterações na disponibilidade e na continuidade do material combustível (Noble; Gilroy; Peres, 2025). Além disso, a utilização do fogo no manejo agropecuário amplia a exposição das áreas adjacentes à vegetação nativa, especialmente em paisagens fragmentadas. Ainda nesse sentido, a interação entre mudança climática e uso da terra pode intensificar o risco de incêndios florestais na Amazônia, especialmente quando a expansão das áreas antropizadas favorece a propagação (Le Page *et al.*, 2017). O mecanismo subjacente é cumulativo: bordas florestais mais secas e com mais combustível morto queimam com maior facilidade (Cochrane, 2001; Silva Junior *et al.*, 2018), o primeiro incêndio aumenta a mortalidade de árvores e abre o dossel (Brando *et al.*, 2014), e a floresta degradada torna-se mais inflamável nos eventos de seca seguintes (Alencar *et al.*, 2015; Lapola *et al.*, 2023), de modo que as áreas de ganho de adequabilidade localizadas junto à fronteira agropecuária (Figura 6) são também aquelas em que esse ciclo de retroalimentação tem maior chance de se estabelecer.

A associação entre as mudanças no uso e na cobertura da terra e a propensão ao fogo também é evidenciada pela contribuição das variáveis aos modelos. Nos modelos futuros, da mesma forma que no cenário presente, a distância às áreas agropecuárias foi a variável de maior importância. Esse resultado é consistente com os dados do MapBiomas (2025a), que apontam o Pará como o estado com maior extensão de estradas na Amazônia, totalizando aproximadamente 211 mil km de vias, cuja presença pode favorecer o desmatamento, a exploração madeireira e a ocupação irregular do território. Nesse contexto, a proximidade das áreas agropecuárias e a infraestrutura viária podem estar relacionadas à dinâmica do fogo, considerando a associação entre incêndios, desmatamento e práticas de manejo de pastagens (Santana *et al.*, 2024).

Por outro lado, a variação da temperatura anual também apresentou contribuição relevante nos modelos futuros. Esse resultado sugere possíveis alterações na relação entre as temperaturas dos meses mais quentes e mais frios. Paralelamente, diversos estudos destacam a influência das secas na dinâmica dos incêndios na Amazônia (Aragão *et al.*, 2018; Brando *et al.*, 2019; Dutra *et al.*, 2026). Essa interpretação é compatível com Fonseca *et al.* (2019), que identificaram variações espaciais e sazonais na probabilidade futura de ocorrência de fogo na Amazônia brasileira, com diferenças entre cenários

climáticos e de uso da terra, e concluíram que evitar o desmatamento mitigaria substancialmente o efeito das mudanças climáticas sobre a probabilidade de fogo, mesmo no cenário climático mais pessimista. Essa conclusão é particularmente relevante para o Pará, uma vez que as variáveis bioclimáticas usadas aqui não incluem extremos interanuais de seca, que são o principal gatilho dos grandes incêndios florestais (Aragão *et al.*, 2018; Brando *et al.*, 2019), de modo que a magnitude das mudanças projetadas nas médias climáticas de 20 anos provavelmente subestima o risco associado aos anos de seca extrema.

Em conjunto, os resultados indicam que a dinâmica projetada para o Pará não se caracteriza exclusivamente pela expansão ou retração das áreas favoráveis ao fogo, mas pela coexistência de condições persistentes e transições espacialmente distribuídas. Desse modo, as áreas com maior propensão ao fogo situadas em regiões de pressão agropecuária constituem setores prioritários para investigação e prevenção, enquanto as áreas de baixa propensão geralmente ocupadas por floresta requerem atenção diante da possibilidade de alterações futuras nas condições ambientais.

4.5 LIMITAÇÕES E IMPLICAÇÕES PARA A GESTÃO DO FOGO

Os resultados devem ser interpretados à luz de limitações de dados, de método e de projeção. Quanto aos dados, os pontos de presença integram cicatrizes acumuladas ao longo de quatro décadas (1985–2025, conforme informado; a Coleção 4 do MapBiomas Fogo cobre 1985–2024), enquanto a climatologia de referência corresponde a 1970–2000 e a camada de uso e cobertura, ao ano mais recente da Coleção 10. Assim, o modelo relaciona fogo histórico a uma paisagem atual, o que pode superestimar a associação com áreas hoje agropecuárias. Além disso, as cicatrizes não distinguem queimadas de desmatamento, de manejo e incêndios florestais (Barlow *et al.*, 2020), e as variáveis bioclimáticas descrevem médias climáticas, não a frequência de secas extremas que condiciona os grandes incêndios (Aragão *et al.*, 2018; Libonati *et al.*, 2021).

Quanto ao método, a avaliação restringiu-se à AUC com partição aleatória, sem validação espacialmente estruturada, sem métricas dependentes de limiar e sem réplicas reportadas, o que impede estimar a incerteza do próprio modelo e pode inflar o desempenho aparente (Lobo; Jiménez-Valverde; Real, 2008; Roberts *et al.*, 2017). Os hiperparâmetros finais, as classes de *features*, o tipo de saída e o limiar de binarização usado na análise de persistência não foram registrados, o que limita a reprodutibilidade; e os valores de AUC atribuídos aos cenários futuros não constituem validação das projeções. Recomenda-se validação em blocos espaciais, TSS e réplicas em estudos futuros.

Quanto às projeções, foram usados dois GCMs e um único horizonte temporal próximo, no qual a incerteza de cenário é pequena em relação à incerteza de modelo e à variabilidade interna

(Hawkins; Sutton, 2009; Lehner *et al.*, 2020); conjuntos maiores de modelos e horizontes de meio e fim de século permitiriam separar melhor o sinal climático do ruído. As camadas de uso da terra e de distâncias foram mantidas fixas, de modo que as projeções isolam o efeito do clima e não incorporam a expansão agropecuária futura, que, dada a importância de 63% das variáveis antrópicas, é provavelmente o principal vetor de mudança da probabilidade de fogo no estado (Silvestrini *et al.*, 2011; Fonseca *et al.*, 2019; Le Page *et al.*, 2017). As classes adotadas são convenções cartográficas, não limiares de risco operacional (Merow; Smith; Silander, 2013). Por fim, as estimativas representam a probabilidade ambiental de ocorrência, não constituindo previsões de incêndios em anos específicos.

Apesar dessas restrições, o estudo oferece contribuições empírica e territorial: fornece a primeira estimativa, para o conjunto do Pará, da probabilidade de ocorrência de fogo baseada em cicatrizes do MapBiomas e projetada com modelos do CMIP6, e mostra que seu padrão espacial é robusto entre modelos e cenários em 2021–2040. Para a gestão, a concentração das classes alta e muito alta e das áreas de ganho de adequabilidade na fronteira agropecuária do sul, sudeste e leste indica onde os instrumentos da Política Nacional de Manejo Integrado do Fogo — planos de manejo integrado, brigadas e sistemas de informação — têm maior potencial de reduzir incêndios (Brasil, 2024; Pivello *et al.*, 2021); as unidades de conservação limítrofes a classes moderadas a muito altas, como a Reserva Biológica Nascentes da Serra do Cachimbo, requerem controle do uso do fogo no entorno; e, como o preditor de maior peso é a proximidade da agropecuária, a contenção do desmatamento e a substituição do fogo no manejo de pastagens atuam diretamente sobre ele, enquanto a adaptação climática deve priorizar os anos de seca extrema, não capturados pelas médias aqui utilizadas.

5 CONCLUSÃO

O estudo permitiu analisar a probabilidade de ocorrência de incêndios no estado do Pará, identificar as principais variáveis preditoras e comparar os padrões espaciais projetados para o período de 2021–2040 sob diferentes cenários climáticos. Os resultados demonstraram que a distância às áreas agropecuárias foi a variável de maior importância nos modelos, seguida pela amplitude térmica anual e pela distância às áreas não vegetadas. Esses resultados evidenciam a relevância das características de uso e cobertura da terra e das condições climáticas para compreender a distribuição espacial da probabilidade de ocorrência de incêndios no estado. No cenário de referência, cerca de 30% do território apresentou probabilidade moderada a muito alta, concentrada nas porções sul, sudeste e leste, onde as áreas agropecuárias respondem por mais de 60% das classes alta e muito alta.

As projeções indicaram a manutenção de padrões espaciais gerais, com maior probabilidade de ocorrência de incêndios nas porções sul, sudeste e leste do Pará e predominância de classes de menor probabilidade no oeste. Entretanto, as diferenças entre os modelos MIROC6 e HadGEM3-GC31-LL demonstraram que a magnitude e a distribuição das mudanças variam conforme o modelo climático e o cenário considerado, e as mudanças de área por classe não ultrapassaram 2,1 pontos percentuais do território no horizonte analisado. Essa variação reforça a importância de utilizar diferentes projeções na avaliação das possíveis mudanças na distribuição espacial da probabilidade de incêndios.

Os resultados contribuem para o conhecimento dos fatores associados à ocorrência de incêndios no Pará e fornecem subsídios para o planejamento de ações de prevenção, o monitoramento ambiental e a identificação de áreas prioritárias para a gestão do fogo, especialmente nas regiões sob pressão da expansão agropecuária e das transformações da cobertura vegetal. Ressalta-se que as estimativas representam a probabilidade ambiental de ocorrência, não constituindo previsões diretas de incêndios futuros, e que as projeções isolam o efeito do clima médio, sem incorporar cenários de uso da terra nem a frequência de secas extremas. Pesquisas posteriores poderão incorporar outras variáveis ambientais e antrópicas, cenários de uso da terra, conjuntos maiores de modelos climáticos e horizontes mais distantes, e ampliar os procedimentos de validação, contribuindo para aprimorar as projeções e apoiar estratégias de prevenção mais adequadas às particularidades territoriais do estado.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro concedido por meio das bolsas de pós-graduação, bem como ao Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente (PPGM), da Universidade Estadual de Feira de Santana (UEFS), pelo suporte institucional e pela formação acadêmica que contribuíram para o desenvolvimento desta pesquisa.

Este trabalho foi apoiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e pelo Ministério da Ciência, Tecnologia e Inovação (MCTI), por meio do edital CNPq/MCTI nº 441271/2023-5 – Presente, Passado e Futuro da Biodiversidade do Semiárido: Inventários, Monitoramento, Impactos das Mudanças Climáticas e Implicações para o Uso e Conservação da Flora, Fauna e Fungos. W.J.F.R. foi apoiado por bolsa de produtividade em pesquisa do CNPq (processo nº 314954/2021-0), Projeto Prospecta 4.0 – CNPq (processo nº 407907/2022-0) e pelo projeto 30202010010121001 – CTBIO – FINEP, associada ao Centro Temático de Bioeconomia do Semiárido (UEFS – CTBio-CIMATEC SERTÃO). Os autores agradecem ao Instituto Nacional de Ciência e Tecnologia em Estudos Interdisciplinares e Transdisciplinares em Ecologia e Evolução (INCT IN-

TREE), financiado pelo CNPq (408930/2024-1), pela CAPES (88887.195651/2025-00) e pela FAPESP. Financiamento adicional foi fornecido pela Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB), por meio do programa Bioeconomia, Recursos Hídricos e Sustentabilidade Ambiental na Bahia, no âmbito da Chamada nº 38/2022, Acordo de Cooperação Técnica nº 294/2023 e Termo de Outorga nº PPF0003/2023. Os autores agradecem ao Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente (PPGM/UEFS) pelo apoio institucional, bem como ao SENAI CIMATEC pela contribuição no desenvolvimento científico e tecnológico voltado à inovação aplicada. R.N.V. foi apoiado pelo INCT IN-TREE e agradece a bolsa SET-G 30202010010121001 – CTBIO – FINEP, associada ao Centro Temático de Bioeconomia do Semiárido (UEFS – CTBio-CIMATEC SERTÃO), vinculado a Projetos Especiais.

REFERÊNCIAS

ALENCAR, Ane A.; BRANDO, Paulo M.; ASNER, Gregory P. *et al.* Landscape fragmentation, severe drought, and the new Amazon forest fire regime. Ecological Applications, v. 25, n. 6, p. 1493-1505, 2015. DOI: https://doi.org/10.1890/14-1528.1.

ALENCAR, Ane A. C.; ARRUDA, Vera L. S.; SILVA, Wallace Vieira da *et al.* Long-term Landsat-based monthly burned area dataset for the Brazilian biomes using deep learning. Remote Sensing, v. 14, n. 11, 2510, 2022. DOI: https://doi.org/10.3390/rs14112510.

ALLOUCHE, Omri; TSOAR, Asaf; KADMON, Ronen. Assessing the accuracy of species distribution models: prevalence, kappa and the true skill statistic (TSS). Journal of Applied Ecology, v. 43, n. 6, p. 1223-1232, 2006. DOI: https://doi.org/10.1111/j.1365-2664.2006.01214.x.

ALVES, Daniel Borini; PÉREZ-CABELLO, Fernando. Multiple remote sensing data sources to assess spatio-temporal patterns of fire incidence over Campos Amazônicos Savanna Vegetation Enclave (Brazilian Amazon). Science of The Total Environment, v. 601-602, p. 142-158, 2017. DOI: https://doi.org/10.1016/j.scitotenv.2017.05.194.

ANDREWS, Timothy; ANDREWS, Martin B.; BODAS-SALCEDO, Alejandro *et al.* Forcings, feedbacks, and climate sensitivity in HadGEM3-GC3.1 and UKESM1. Journal of Advances in Modeling Earth Systems, v. 11, n. 12, p. 4377-4394, 2019. DOI: https://doi.org/10.1029/2019MS001866.

ARAGÃO, Luiz E. O. C.; ANDERSON, Liana O.; FONSECA, Marisa G. *et al.* 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. Nature Communications, v. 9, n. 1, 536, 2018. DOI: https://doi.org/10.1038/s41467-017-02771-y.

ARRUDA, Vera Laísa da Silva; ALENCAR, Ane Auxiliadora Costa; CARVALHO JÚNIOR, Osmar Abílio de *et al.* Assessing four decades of fire behavior dynamics in the Cerrado biome (1985 to 2022). Fire Ecology, v. 20, n. 1, 64, 2024. DOI: https://doi.org/10.1186/s42408-024-00298-4.

BARLOW, Jos; BERENGUER, Erika; CARMENTA, Rachel *et al.* Clarifying Amazonia's burning crisis. Global Change Biology, v. 26, n. 2, p. 319-321, 2020. DOI: https://doi.org/10.1111/gcb.14872.

BORIA, Robert A.; OLSON, Link E.; GOODMAN, Steven M. *et al.* Spatial filtering to reduce sampling bias can improve the performance of ecological niche models. Ecological Modelling, v. 275, p. 73-77, 2014. DOI: https://doi.org/10.1016/j.ecolmodel.2013.12.012.

BRANDO, Paulo Monteiro; BALCH, Jennifer K.; NEPSTAD, Daniel C. *et al.* Abrupt increases in Amazonian tree mortality due to drought-fire interactions. Proceedings of the National Academy of Sciences, v. 111, n. 17, p. 6347-6352, 2014. DOI: https://doi.org/10.1073/pnas.1305499111.

BRANDO, Paulo M.; PAOLUCCI, Lucas; UMMENHOFER, Caroline C. *et al.* Droughts, wildfires, and forest carbon cycling: a pantropical synthesis. Annual Review of Earth and Planetary Sciences, v. 47, n. 1, p. 555-581, 2019. DOI: https://doi.org/10.1146/annurev-earth-082517-010235.

BRANDO, P. M.; SOARES-FILHO, B.; RODRIGUES, L. *et al.* The gathering firestorm in southern Amazonia. Science Advances, v. 6, n. 2, eaay1632, 2020. DOI: https://doi.org/10.1126/sciadv.aay1632.

BRASIL. Lei nº 14.944, de 31 de julho de 2024. Institui a Política Nacional de Manejo Integrado do Fogo. Diário Oficial da União: seção 1, Brasília, DF, 1 ago. 2024. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2023-2026/2024/lei/l14944.htm. Acesso em: 13 nov. 2026.

BRASIL. Ministério do Meio Ambiente e Mudança do Clima. Cadastro Nacional de Unidades de Conservação: unidades de conservação. Brasília, DF: MMA, 2026. Disponível em: https://dados.mma.gov.br/dataset/unidadesdeconservacao. Acesso em: 13 nov. 2026.

CAMPANHARO, Wesley A.; LOPES, Aline P.; ANDERSON, Liana O. *et al.* Translating fire impacts in southwestern Amazonia into economic costs. Remote Sensing, v. 11, n. 7, 764, 2019. DOI: https://doi.org/10.3390/rs11070764.

CANO-CRESPO, Ana; OLIVEIRA, Paulo J. C.; BOIT, Alice *et al.* Forest edge burning in the Brazilian Amazon promoted by escaping fires from managed pastures. Journal of Geophysical Research: Biogeosciences, v. 120, n. 10, p. 2095-2107, 2015. DOI: https://doi.org/10.1002/2015JG002914.

CHICAS, Santos Daniel; NIELSEN, Jonas Østergaard. Who are the actors and what are the factors that are used in models to map forest fire susceptibility? A systematic review. Natural Hazards, v. 114, n. 3, p. 2417-2434, 2022. DOI: https://doi.org/10.1007/s11069-022-05495-5.

COCHRANE, Mark A. Synergistic interactions between habitat fragmentation and fire in evergreen tropical forests. Conservation Biology, v. 15, n. 6, p. 1515-1521, 2001. DOI: https://doi.org/10.1046/j.1523-1739.2001.01091.x.

DANTAS, Leydson G.; SANTOS, Carlos A. C. dos; SANTOS, Celso A. G. *et al.* Future changes in temperature and precipitation over Northeastern Brazil by CMIP6 model. Water, v. 14, n. 24, 4118, 2022. DOI: https://doi.org/10.3390/w14244118.

DUTRA, Débora Joana; FERREIRA, Igor José Malfetoni; RODRIGUES, Érick Teixeira *et al.* Intensification of drought-associated wildfires challenges actions for Amazonia's sustainable development. Perspectives in Ecology and Conservation, v. 24, n. 2, p. 146-150, 2026. DOI: https://doi.org/10.1016/j.pecon.2026.02.013.

ELITH, Jane; PHILLIPS, Steven J.; HASTIE, Trevor *et al.* A statistical explanation of MaxEnt for ecologists. Diversity and Distributions, v. 17, n. 1, p. 43-57, 2011. DOI: https://doi.org/10.1111/j.1472-4642.2010.00725.x.

FICK, Stephen E.; HIJMANS, Robert J. WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. International Journal of Climatology, v. 37, n. 12, p. 4302-4315, 2017. DOI: https://doi.org/10.1002/joc.5086.

FLANNIGAN, M. D.; WOTTON, B. M.; MARSHALL, G. A. *et al.* Fuel moisture sensitivity to temperature and precipitation: climate change implications. Climatic Change, v. 134, n. 1-2, p. 59-71, 2016. DOI: https://doi.org/10.1007/s10584-015-1521-0.

FONSECA, Marisa G.; ARAGÃO, Luiz Eduardo O. C.; LIMA, André *et al.* Modelling fire probability in the Brazilian Amazon using the maximum entropy method. International Journal of Wildland Fire, v. 25, n. 9, p. 955-969, 2016. DOI: https://doi.org/10.1071/WF15216.

FONSECA, Marisa Gesteira; ALVES, Lincoln Muniz; AGUIAR, Ana Paula Dutra *et al.* Effects of climate and land-use change scenarios on fire probability during the 21st century in the Brazilian Amazon. Global Change Biology, v. 25, n. 9, p. 2931-2946, 2019. DOI: https://doi.org/10.1111/gcb.14709.

FUNAI – Fundação Nacional dos Povos Indígenas. Geoprocessamento e mapas: terras indígenas. Brasília, DF: FUNAI, 2026. Disponível em: https://www.gov.br/funai/pt-br/atuacao/terras-indigenas/geoprocessamento-e-mapas. Acesso em: 13 nov. 2026.

GOLTAS, Merih. Predicting forest fire probability under current conditions and future climate change scenarios in Türkiye. Forest Ecosystems, v. 17, 100525, 2026. DOI: https://doi.org/10.1016/j.fecs.2026.100525.

HARDESTY, Jeff; MYERS, Ron; FULKS, Wendy. Fire, ecosystems and people: a preliminary assessment of fire as a global conservation issue. The George Wright Forum, v. 22, n. 4, p. 78-87, 2005. Disponível em: https://www.georgewright.org/224hardesty.pdf. Acesso em: 21 out. 2026.

HAWKINS, Ed; SUTTON, Rowan. The potential to narrow uncertainty in regional climate predictions. Bulletin of the American Meteorological Society, v. 90, n. 8, p. 1095-1108, 2009. DOI: https://doi.org/10.1175/2009BAMS2607.1.

IBAN, Muzaffer Can; SEKERTEKIN, Aliihsan. Machine learning based wildfire susceptibility mapping using remotely sensed fire data and GIS: a case study of Adana and Mersin provinces, Turkey. Ecological Informatics, v. 69, 101647, 2022. DOI: https://doi.org/10.1016/j.ecoinf.2022.101647.

IBGE – Instituto Brasileiro de Geografia e Estatística. Pará: cidades e estados. Rio de Janeiro: IBGE, 2025. Disponível em: https://www.ibge.gov.br/cidades-e-estados/pa/. Acesso em: 20 out. 2026.

IPCC – Intergovernmental Panel on Climate Change. Climate change 2021: the physical science basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge; New York: Cambridge University Press, 2021. DOI: https://doi.org/10.1017/9781009157896.

JAIN, Piyush; COOGAN, Sean C. P.; SUBRAMANIAN, Sriram Ganapathi *et al.* A review of machine learning applications in wildfire science and management. Environmental Reviews, v. 28, n. 4, p. 478-505, 2020. DOI: https://doi.org/10.1139/er-2020-0019.

JESUS, Janisson Batista de; ROSA, Cristiano Niederauer da; BARRETO, Íkaro Daniel de Carvalho *et al.* Análise da incidência temporal, espacial e de tendência de fogo nos biomas e unidades de conservação do Brasil. Ciência Florestal, v. 30, n. 1, p. 176-191, 2020. DOI: https://doi.org/10.5902/1980509837696.

JONES, Matthew W.; ABATZOGLOU, John T.; VERAVERBEKE, Sander *et al.* Global and regional trends and drivers of fire under climate change. Reviews of Geophysics, v. 60, n. 3, e2020RG000726, 2022. DOI: https://doi.org/10.1029/2020RG000726.

KELLEY, Douglas I.; BISTINAS, Ioannis; WHITLEY, Rhys *et al.* How contemporary bioclimatic and human controls change global fire regimes. Nature Climate Change, v. 9, n. 9, p. 690-696, 2019. DOI: https://doi.org/10.1038/s41558-019-0540-7.

KELLEY, Douglas I.; BURTON, Chantelle; HUNTINGFORD, Chris *et al.* Technical note: low meteorological influence found in 2019 Amazonia fires. Biogeosciences, v. 18, n. 3, p. 787-804, 2021. DOI: https://doi.org/10.5194/bg-18-787-2021.

KOTTEK, Markus; GRIESER, Jürgen; BECK, Christoph *et al.* World map of the Köppen-Geiger climate classification updated. Meteorologische Zeitschrift, v. 15, n. 3, p. 259-263, 2006. DOI: https://doi.org/10.1127/0941-2948/2006/0130.

LAPOLA, David M.; PINHO, Patricia; BARLOW, Jos *et al.* The drivers and impacts of Amazon forest degradation. Science, v. 379, n. 6630, eabp8622, 2023. DOI: https://doi.org/10.1126/science.abp8622.

LE PAGE, Yannick; MORTON, Douglas; HARTIN, Corinne *et al.* Synergy between land use and climate change increases future fire risk in Amazon forests. Earth System Dynamics, v. 8, n. 4, p. 1237-1246, 2017. DOI: https://doi.org/10.5194/esd-8-1237-2017.

LEHNER, Flavio; DESER, Clara; MAHER, Nicola *et al.* Partitioning climate projection uncertainty with multiple large ensembles and CMIP5/6. Earth System Dynamics, v. 11, n. 2, p. 491-508, 2020. DOI: https://doi.org/10.5194/esd-11-491-2020.

LIBONATI, R.; PEREIRA, J. M. C.; DA CAMARA, C. C. *et al.* Twenty-first century droughts have not increasingly exacerbated fire season severity in the Brazilian Amazon. Scientific Reports, v. 11, n. 1, 4400, 2021. DOI: https://doi.org/10.1038/s41598-021-82158-8.

LOBO, Jorge M.; JIMÉNEZ-VALVERDE, Alberto; REAL, Raimundo. AUC: a misleading measure of the performance of predictive distribution models. Global Ecology and Biogeography, v. 17, n. 2, p. 145-151, 2008. DOI: https://doi.org/10.1111/j.1466-8238.2007.00358.x.

MACHADO-SILVA, Fausto; LIBONATI, Renata; MELO DE LIMA, Thiago Felipe *et al.* Drought and fires influence the respiratory diseases hospitalizations in the Amazon. Ecological Indicators, v. 109, 105817, 2020. DOI: https://doi.org/10.1016/j.ecolind.2019.105817.

MAPBIOMAS. Coleção 10 da série anual de mapas de cobertura e uso da terra do Brasil. São Paulo: MapBiomas, 2025a. Disponível em: https://brasil.mapbiomas.org/. Acesso em: 13 nov. 2026.

MAPBIOMAS. Relatório Anual do Fogo no Brasil: RAF 2025 – Coleção 4 de mapas de áreas queimadas do MapBiomas Fogo (1985 a 2024). São Paulo: MapBiomas, 2025b. Disponível em: https://brasil.mapbiomas.org/iniciativas-e-produtos/fogo/. Acesso em: 13 nov. 2026.

MARTINS, Henrique Parizotto Lacaz; FRANCISCO, Eduardo de Rezende. Determinantes do desmatamento histórico e recente da Amazônia na perspectiva da estatística espacial. Cadernos Gestão Pública e Cidadania, v. 30, e91454, 2025. DOI: https://doi.org/10.12660/cgpc.v30.91454.

MATAVELI, Guilherme; JONES, Matthew W.; CARMENTA, Rachel *et al.* Deforestation falls but rise of wildfires continues degrading Brazilian Amazon forests. Global Change Biology, v. 30, n. 2, e17202, 2024. DOI: https://doi.org/10.1111/gcb.17202.

MEEHL, Gerald A.; SENIOR, Catherine A.; EYRING, Veronika *et al.* Context for interpreting equilibrium climate sensitivity and transient climate response from the CMIP6 Earth system models. Science Advances, v. 6, n. 26, eaba1981, 2020. DOI: https://doi.org/10.1126/sciadv.aba1981.

MEROW, Cory; SMITH, Matthew J.; SILANDER, John A. 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. DOI: https://doi.org/10.1111/j.1600-0587.2013.07872.x.

MORAES, Bergson Cavalcanti de; COSTA, José Maria Nogueira da; COSTA, Antonio Carlos Lôla da *et al.* Variação espacial e temporal da precipitação no Estado do Pará. Acta Amazonica, v. 35, n. 2, p. 207-214, 2005. DOI: https://doi.org/10.1590/S0044-59672005000200010.

MORITZ, Max A.; PARISIEN, Marc-André; BATLLORI, Enric *et al.* Climate change and disruptions to global fire activity. Ecosphere, v. 3, n. 6, p. 1-22, 2012. DOI: https://doi.org/10.1890/ES11-00345.1.

MORTON, D. C.; LE PAGE, Y.; DEFRIES, R. *et al.* Understorey fire frequency and the fate of burned forests in southern Amazonia. Philosophical Transactions of the Royal Society B: Biological Sciences, v. 368, n. 1619, 20120163, 2013. DOI: https://doi.org/10.1098/rstb.2012.0163.

NEPSTAD, Daniel; LEFEBVRE, Paul; LOPES DA SILVA, Urbano *et al.* Amazon drought and its implications for forest flammability and tree growth: a basin-wide analysis. Global Change Biology, v. 10, n. 5, p. 704-717, 2004. DOI: https://doi.org/10.1111/j.1529-8817.2003.00772.x.

NEVES, Laís Fernandes de Souza; MARIMON, Beatriz Schwantes; ANDERSON, Liana Oighenstein *et al.* Dinâmica de fogo no Parque Estadual do Araguaia, zona de transição Amazônia-Cerrado. Raega – O Espaço Geográfico em Análise, v. 44, p. 85-103, 2018. DOI: https://doi.org/10.5380/raega.v44i0.47926.

NOBLE, Ciar D.; GILROY, James J.; PERES, Carlos A. Small forest patches and landscape-scale fragmentation exacerbate forest fire prevalence in Amazonia. Journal of Environmental Management, v. 375, 124312, 2025. DOI: https://doi.org/10.1016/j.jenvman.2025.124312.

O'NEILL, Brian C.; KRIEGLER, Elmar; RIAHI, Keywan *et al.* A new scenario framework for climate change research: the concept of shared socioeconomic pathways. Climatic Change, v. 122, n. 3, p. 387-400, 2014. DOI: https://doi.org/10.1007/s10584-013-0905-2.

O'NEILL, Brian C.; TEBALDI, Claudia; VAN VUUREN, Detlef P. *et al.* The Scenario Model Intercomparison Project (ScenarioMIP) for CMIP6. Geoscientific Model Development, v. 9, n. 9, p. 3461-3482, 2016. DOI: https://doi.org/10.5194/gmd-9-3461-2016.

PARISIEN, Marc-André; MORITZ, Max A. Environmental controls on the distribution of wildfire at multiple spatial scales. Ecological Monographs, v. 79, n. 1, p. 127-154, 2009. DOI: https://doi.org/10.1890/07-1289.1.

PHILLIPS, Steven J.; ANDERSON, Robert P.; SCHAPIRE, Robert E. Maximum entropy modeling of species geographic distributions. Ecological Modelling, v. 190, n. 3-4, p. 231-259, 2006. DOI: https://doi.org/10.1016/j.ecolmodel.2005.03.026.

PIELKE JR, Roger; BURGESS, Matthew G.; RITCHIE, Justin. Plausible 2005–2050 emissions scenarios project between 2 °C and 3 °C of warming by 2100. Environmental Research Letters, v. 17, n. 2, 024027, 2022. DOI: https://doi.org/10.1088/1748-9326/ac4ebf.

PINHO, Patrícia F.; SILVESTRINI, Rafaella; FELLOWS, Martha *et al.* Vulnerabilities and compound risks of escalating climate disasters in the Brazilian Amazon. Nature Communications, v. 16, n. 1, 11579, 2025. DOI: https://doi.org/10.1038/s41467-025-66603-0.

PIVELLO, Vânia R. The use of fire in the Cerrado and Amazonian rainforests of Brazil: past and present. Fire Ecology, v. 7, n. 1, p. 24-39, 2011. DOI: https://doi.org/10.4996/fireecology.0701024.

PIVELLO, Vânia R.; VIEIRA, Ima; CHRISTIANINI, Alexander V. *et al.* Understanding Brazil's catastrophic fires: causes, consequences and policy needed to prevent future tragedies. Perspectives in Ecology and Conservation, v. 19, n. 3, p. 233-255, 2021. DOI: https://doi.org/10.1016/j.pecon.2021.06.005.

RADOSAVLJEVIC, Aleksandar; ANDERSON, Robert P. Making better Maxent models of species distributions: complexity, overfitting and evaluation. Journal of Biogeography, v. 41, n. 4, p. 629-643, 2014. DOI: https://doi.org/10.1111/jbi.12227.

REIS, Mateus dos; GRAÇA, Paulo Maurício Lima de Alencastro; YANAI, Aurora Miho *et al.* Forest fires and deforestation in the central Amazon: effects of landscape and climate on spatial and temporal dynamics. Journal of Environmental Management, v. 288, 112310, 2021. DOI: https://doi.org/10.1016/j.jenvman.2021.112310.

RIBEIRO, Andreia F. S.; SANTOS, Lucas; RANDERSON, James T. *et al.* The time since land-use transition drives changes in fire activity in the Amazon-Cerrado region. Communications Earth & Environment, v. 5, n. 1, 96, 2024. DOI: https://doi.org/10.1038/s43247-024-01248-3.

RIBEIRO, Thais Marcolino; MENDONÇA, Bruno Araujo Furtado de; OLIVEIRA-JÚNIOR, José Francisco de *et al.* Fire foci assessment in the Western Amazon (2000–2015). Environment, Development and Sustainability, v. 23, n. 2, p. 1485-1498, 2021. DOI: https://doi.org/10.1007/s10668-020-00632-1.

ROBERTS, David R.; BAHN, Volker; CIUTI, Simone *et al.* Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. Ecography, v. 40, n. 8, p. 913-929, 2017. DOI: https://doi.org/10.1111/ecog.02881.

SALOMÃO, Natália Viveiros; FERNANDES, Geraldo Wilson; GONZAGA, Anne Priscila Dias *et al.* Spatial analysis of fire severity and its relationship with landscape configuration in savanna areas of Sempre Vivas National Park, Brazil. Revista Brasileira de Geografia Física, v. 17, n. 3, p. 1894-1904, 2024. DOI: https://doi.org/10.26848/rbgf.v17.3.p1894-1904.

SANTANA, Mariana Martins Medeiros de; VASCONCELOS, Rodrigo Nogueira de; MARIANO-NETO, Eduardo. Fire propensity in Amazon savannas and rainforest and effects under future climate change. International Journal of Wildland Fire, v. 32, n. 2, p. 149-163, 2023. DOI: https://doi.org/10.1071/WF21174.

SANTANA, Mariana Martins Medeiros de; VASCONCELOS, Rodrigo Nogueira de; MARIANO NETO, Eduardo *et al.* Machine learning model reveals land use and climate's role in Amazon wildfires: present and future scenarios. Fire, v. 7, n. 10, 338, 2024. DOI: https://doi.org/10.3390/fire7100338.

SANTOS, Hana Saiumy Favacho dos; GONÇALVES, Amaury Caldeira de Lima; MOTA, Iolanda Laranjeira *et al.* Padrões de áreas queimadas e análise de riscos de incêndios florestais no estado do Pará, Brasil. Nativa, v. 14, n. 3, e21761, 2026. DOI: https://doi.org/10.31413/nat.v14i3.21761.

SILVA, Camila V. J.; ARAGÃO, Luiz E. O. C.; BARLOW, Jos *et al.* Drought-induced Amazonian wildfires instigate a decadal-scale disruption of forest carbon dynamics. Philosophical Transactions of the Royal Society B: Biological Sciences, v. 373, n. 1760, 20180043, 2018. DOI: https://doi.org/10.1098/rstb.2018.0043.

SILVA JUNIOR, Celso H. L.; ARAGÃO, Luiz E. O. C.; FONSECA, Marisa G. *et al.* Deforestation-induced fragmentation increases forest fire occurrence in central Brazilian Amazonia. Forests, v. 9, n. 6, 305, 2018. DOI: https://doi.org/10.3390/f9060305.

SILVEIRA, Marcus V. F.; PETRI, Caio A.; BROGGIO, Igor S. *et al.* Drivers of fire anomalies in the Brazilian Amazon: lessons learned from the 2019 fire crisis. Land, v. 9, n. 12, 516, 2020. DOI: https://doi.org/10.3390/land9120516.

SILVESTRINI, Rafaella Almeida; SOARES-FILHO, Britaldo Silveira; NEPSTAD, Daniel *et al.* Simulating fire regimes in the Amazon in response to climate change and deforestation. Ecological Applications, v. 21, n. 5, p. 1573-1590, 2011. DOI: https://doi.org/10.1890/10-0827.1.

SMITH, Lauren T.; ARAGÃO, Luiz E. O. C.; SABEL, Clive E. *et al.* Drought impacts on children's respiratory health in the Brazilian Amazon. Scientific Reports, v. 4, n. 1, 3726, 2014. DOI: https://doi.org/10.1038/srep03726.

SOUZA, Carlos M.; SHIMBO, Julia Z.; ROSA, Marcos R. *et al.* Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and Earth Engine. Remote Sensing, v. 12, n. 17, 2735, 2020. DOI: https://doi.org/10.3390/rs12172735.

SOUZA, Carlos M.; OLIVEIRA, Luis A.; SOUZA FILHO, Jailson S. de *et al.* Landsat sub-pixel land cover dynamics in the Brazilian Amazon. Frontiers in Forests and Global Change, v. 6, 1294552, 2023. DOI: https://doi.org/10.3389/ffgc.2023.1294552.

TATEBE, Hiroaki; OGURA, Tomoo; NITTA, Tomoko *et al.* Description and basic evaluation of simulated mean state, internal variability, and climate sensitivity in MIROC6. Geoscientific Model Development, v. 12, n. 7, p. 2727-2765, 2019. DOI: https://doi.org/10.5194/gmd-12-2727-2019.

TEBALDI, Claudia; DEBEIRE, Kevin; EYRING, Veronika *et al.* Climate model projections from the Scenario Model Intercomparison Project (ScenarioMIP) of CMIP6. Earth System Dynamics, v. 12, n. 1, p. 253-293, 2021. DOI: https://doi.org/10.5194/esd-12-253-2021.

TONBUL, Hasan; VERAVERBEKE, Sander. Machine-learning wildfire susceptibility mapping with SHAP-based explainability in Türkiye's fire-prone regions. Stochastic Environmental Research and Risk Assessment, v. 40, n. 1, 2, 2026. DOI: https://doi.org/10.1007/s00477-025-03136-4.

VASCONCELOS, Rodrigo N.; SANTANA, Mariana M. M. de; COSTA, Diego P. *et al.* Machine learning model reveals land use and climate's role in Caatinga wildfires: present and future scenarios. Fire, v. 8, n. 1, 8, 2024. DOI: https://doi.org/10.3390/fire8010008.

VIGNALI, Sergio; BARRAS, Arnaud G.; ARLETTAZ, Raphaël *et al.* SDMtune: an R package to tune and evaluate species distribution models. Ecology and Evolution, v. 10, n. 20, p. 11488-11506, 2020. DOI: https://doi.org/10.1002/ece3.6786.

WHALEY, Cynthia; LI, Yang; VALIQUETTE, Isabelle *et al.* Current model capabilities and future predictive pathways of wildfires under a changing climate. Communications Earth & Environment, v. 7, n. 1, 749, 2026. DOI: https://doi.org/10.1038/s43247-026-04013-w.

WHITE, Benjamin Leonardo Alves. Spatiotemporal variation in fire occurrence in the state of Amazonas, Brazil, between 2003 and 2016. Acta Amazonica, v. 48, n. 4, p. 358-367, 2018. DOI: https://doi.org/10.1590/1809-4392201704522.

XU, Wenxuan; CEN, Jiamin; FAN, Lei *et al.* Land use and climatic drivers of early 21st-century fire activity in the Amazon. Agricultural and Forest Meteorology, v. 372, 110664, 2025. DOI: https://doi.org/10.1016/j.agrformet.2025.110664.

YESILNACAR, Ertan; TOPAL, Tamer. Landslide susceptibility mapping: a comparison of logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey). Engineering Geology, v. 79, n. 3-4, p. 251-266, 2005. DOI: https://doi.org/10.1016/j.enggeo.2005.02.002.

ZHANG, Cunhui; JANSSEN, Thomas A. J.; MORIS, Jose V. *et al.* Are there lightning fires in the Brazilian Amazon? Environmental Research Letters, v. 21, n. 2, 024025, 2026. DOI: https://doi.org/10.1088/1748-9326/ae3786.