ReGeo ISSN: 2177-3246

INCÊNDIOS FLORESTAIS EM MATO GROSSO: PADRÕES ESPACIAIS E PROJEÇÕES EM CENÁRIOS ATUAIS E FUTUROS

FOREST FIRES IN MATO GROSSO: SPATIAL PATTERNS AND PROJECTIONS UNDER CURRENT AND FUTURE SCENARIOS

INCENDIOS FORESTALES EN MATO GROSSO: PATRONES ESPACIALES Y PROYECCIONES EN ESCENARIOS ACTUALES Y FUTUROS

https://doi.org/10.56238/revgeov17n11-150

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

Jéssica Figuera Oliveira Miranda
Mestra em Modelagem e Simulação de Biossistemas
Instituição: Universidade Estadual de Feira de Santana (UEFS)
E-mail: j.figuera@ufms.br

Ana Paula de Sena de Souza
Mestra em Modelagem em Ciências da Terra e do Ambiente
Instituição: Universidade Estadual de Feira de Santana (UEFS)
E-mail: anapaulasouza.geo2023@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

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

RESUMO
Os incêndios florestais representam um importante problema ambiental, tornando necessária a identificação de áreas suscetíveis e de possíveis alterações em sua distribuição diante das mudanças climáticas. Este estudo avaliou a propensão à ocorrência de fogo no estado de Mato Grosso, Brasil, em condições presentes e futuras, utilizando o algoritmo MaxEnt e variáveis climáticas e topográficas. Os registros de ocorrência foram obtidos do MapBiomas Fogo, enquanto as condições climáticas

presentes foram provenientes do WorldClim 2.1. Para as projeções de 2021–2040, foram utilizados os modelos climáticos MIROC6 e HadGEM3-GC31-LL sob os cenários SSP1-2.6 e SSP5-8.5. O modelo final apresentou AUC de 0,837 no treinamento e 0,830 no teste, indicando desempenho preditivo satisfatório e estabilidade, com TSS de aproximadamente 0,54. A sazonalidade da temperatura, a temperatura máxima do mês mais quente e a amplitude térmica anual foram os principais preditores. Atualmente, as áreas de maior propensão concentram-se principalmente no Cerrado e em zonas de transição entre Amazônia e Cerrado. As projeções indicaram expansão das classes alta e muito alta, que passaram de aproximadamente 19% da área analisada no presente para cerca de 49% no SSP1-2.6 e 46% no SSP5-8.5. As zonas de transição também apresentaram maior incerteza entre os modelos climáticos. Os resultados evidenciam a possibilidade de expansão espacial da propensão ao fogo nas próximas décadas, mas devem ser lidos como projeções condicionais, que mantêm o uso da terra constante, não incluem fatores de ignição humana nem avaliação de extrapolação ambiental. Eles fornecem subsídios para o direcionamento de estratégias de prevenção, monitoramento e gestão territorial em Mato Grosso.

Palavras-chave: Incêndios Florestais. MaxEnt. Modelagem Espacial. Mato Grosso.

ABSTRACT
Wildfires represent a significant environmental issue, necessitating the identification of susceptible areas and potential shifts in their distribution due to climate change. This study assessed fire susceptibility in the state of Mato Grosso, Brazil, under present and future conditions using the MaxEnt algorithm alongside climatic and topographic variables. Fire occurrence records were obtained from MapBiomas Fogo, while present climatic data came from WorldClim 2.1. For projections covering 2021–2040, the MIROC6 and HadGEM3-GC31-LL climate models were used under the SSP1-2.6 and SSP5-8.5 scenarios. The final model yielded an AUC of 0.837 for training and 0.830 for testing, indicating satisfactory predictive performance and stability, with a TSS of approximately 0.54. Temperature seasonality, maximum temperature of the warmest month, and annual temperature range were the primary predictors. Currently, areas of highest susceptibility are concentrated mainly in the Cerrado biome and in transition zones between the Amazon and the Cerrado. Projections indicated an expansion of the “high” and “very high” susceptibility classes, rising from approximately 19% of the analyzed area at present to about 49% under SSP1-2.6 and 46% under SSP5-8.5. Transition zones also exhibited greater uncertainty across the climate models. The results highlight the potential for a spatial expansion of fire susceptibility in the coming decades, but they should be read as conditional projections that hold land use constant and include neither human ignition factors nor an assessment of environmental extrapolation. They provide a basis for guiding prevention, monitoring, and land-management strategies in Mato Grosso.

Keywords: Forest Fires. MaxEnt. Spatial Modeling. Mato Grosso.

RESUMEN
Los incendios forestales representan un problema ambiental importante, lo que hace necesaria la identificación de áreas susceptibles y de posibles alteraciones en su distribución ante el cambio climático. Este estudio evaluó la propensión a la ocurrencia de incendios en el estado de Mato Grosso, Brasil, bajo condiciones presentes y futuras, utilizando el algoritmo MaxEnt y variables climáticas y topográficas. Los registros de ocurrencia se obtuvieron de MapBiomas Fogo, mientras que las condiciones climáticas presentes provinieron de WorldClim 2.1. Para las proyecciones de 2021-2040, se utilizaron los modelos climáticos MIROC6 y HadGEM3-GC31-LL bajo los escenarios SSP1-2.6 y SSP5-8.5. El modelo final presentó un AUC de 0,837 en el entrenamiento y de 0,830 en la prueba, lo que indica un rendimiento predictivo satisfactorio y estabilidad, con un TSS de aproximadamente 0,54.

La estacionalidad de la temperatura, la temperatura máxima del mes más cálido y la amplitud térmica anual fueron los principales predictores. Actualmente, las áreas de mayor propensión se concentran principalmente en el Cerrado y en zonas de transición entre la Amazonia y el Cerrado. Las proyecciones indicaron una expansión de las clases alta y muy alta, que pasaron de aproximadamente el 19 % del área analizada en la actualidad a cerca del 49 % en el escenario SSP1-2.6 y del 46 % en el SSP5-8.5. Las zonas de transición también mostraron una mayor incertidumbre entre los modelos climáticos. Los resultados evidencian la posibilidad de una expansión espacial de la propensión a los incendios en las próximas décadas, pero deben leerse como proyecciones condicionales, que mantienen constante el uso del suelo y no incluyen factores de ignición humana ni una evaluación de la extrapolación ambiental. Proporcionan elementos para orientar estrategias de prevención, monitoreo y gestión territorial en Mato Grosso.

Palabras clave: Incendios Forestales. MaxEnt. Modelado Espacial. Mato Grosso.

1 INTRODUÇÃO

Os incêndios florestais constituem um importante problema ambiental, caracterizado pela propagação incontrolada do fogo sobre a vegetação e por seu elevado potencial de causar danos aos ecossistemas. No Brasil, grande parte dessas ocorrências está associada à ação humana, especialmente ao uso inadequado do fogo em atividades agropecuárias, à caça e a ações criminosas, embora fenômenos naturais também possam atuar como fontes de ignição em menor proporção. Diante de seu potencial destrutivo, a compreensão das condições relacionadas à ocorrência e à propagação do fogo torna-se fundamental para subsidiar medidas de prevenção e combate (Santos; Soares; Batista, 2006; Pivello *et al.*, 2021).

Para White *et al.* (2016), a ocorrência dos incêndios está relacionada à interação de diferentes fatores ambientais, que podem ser classificados como dinâmicos ou constantes. Entre os fatores dinâmicos destacam-se as condições meteorológicas, como temperatura, umidade relativa do ar, velocidade do vento e precipitação, enquanto os fatores constantes incluem características que apresentam menor variação, como o relevo e o material combustível. A integração das condições meteorológicas permite estimar o perigo de ocorrência de incêndios, enquanto a incorporação da influência humana sobre a ignição possibilita avaliar o risco associado ao fogo. Dessa forma, compreender espacialmente essas variáveis constitui um componente importante para identificar áreas suscetíveis e orientar ações preventivas.

Essa problemática assume particular importância no estado de Mato Grosso (Rodrigues; Crispim; Comastri Filho, 2002), onde diferentes condições ambientais podem influenciar a dinâmica dos incêndios florestais. Entre as áreas afetadas encontra-se o Pantanal Mato-Grossense, parte da maior planície inundável do planeta, caracterizada pela heterogeneidade de clima, solo, água, vegetação e fauna. Durante os períodos de estiagem, os incêndios representam um desafio adicional nesse ambiente, uma vez que aqueles que ocorrem em áreas úmidas estão entre os mais difíceis de extinguir, inclusive pelas dificuldades de deslocamento das equipes de combate em terrenos alagados. Em 2020, a combinação de seca e ondas de calor esteve associada à temporada de fogo sem precedentes no Pantanal (Libonati *et al.*, 2022). Embora essas características evidenciem a vulnerabilidade do Pantanal, a compreensão da dinâmica espacial do fogo demanda uma perspectiva mais abrangente, considerando o território mato-grossense como um todo.

Um dos principais desafios para essa avaliação está na capacidade de identificar não apenas os locais onde os incêndios já ocorreram, mas também áreas potencialmente suscetíveis a novas ocorrências. O histórico de incêndios fornece informações relevantes sobre regiões de maior risco, porém sua utilização isolada não é suficiente para predizer novos locais de incidência (Maeda *et al.*,

2009). Áreas que ainda não foram atingidas pelo fogo não estão necessariamente livres de futuras ocorrências, pois, diante de uma fonte de ignição e de condições meteorológicas favoráveis, o incêndio pode se estabelecer e se propagar. Nesse sentido, a avaliação de risco envolve estimar a probabilidade e a magnitude de efeitos adversos, possibilitando reconhecer espacialmente zonas nas quais o fogo pode ocorrer e se disseminar (Fairbrother; Turnley, 2005).

Essa limitação evidencia a necessidade de abordagens capazes de integrar registros de incêndios e diferentes preditores ambientais para compreender a distribuição espacial do risco em Mato Grosso. A utilização exclusiva do histórico de ocorrências pode deixar de representar áreas suscetíveis ainda não atingidas, tornando necessária a adoção de métodos preditivos que considerem conjuntamente os fatores relacionados à dinâmica do fogo. Nesse contexto, técnicas de aprendizado de máquina e de modelagem de distribuição, como o MaxEnt, oferecem uma abordagem para integrar dados de cicatrizes de incêndio obtidos por sensoriamento remoto e variáveis ambientais, possibilitando avaliar padrões atuais e potenciais alterações futuras na distribuição das áreas de risco (Fonseca *et al.*, 2016; Santana; Vasconcelos; Mariano-Neto, 2023; Vasconcelos *et al.*, 2024). Estudos recentes sobre a propensão ao fogo já exploraram essa abordagem em outros biomas brasileiros, como a Amazônia e a Caatinga (Santana *et al.*, 2024; Vasconcelos *et al.*, 2024), mas ainda é limitada a avaliação espacialmente explícita, para todo o estado de Mato Grosso, que combine os três biomas ali presentes, diferentes modelos climáticos globais e a quantificação da incerteza entre eles.

Do ponto de vista social, aprimorar a identificação das áreas suscetíveis aos incêndios pode contribuir para ações de prevenção e redução dos impactos associados ao fogo. Mudanças no comportamento humano podem colaborar para diminuir o número de ocorrências, destacando também a importância de estratégias preventivas e da educação ambiental. Além disso, mapas de risco constituem instrumentos relevantes para delimitar áreas prioritárias e orientar a alocação de equipes brigadistas, contribuindo para minimizar possíveis danos provocados pelos incêndios (Chou; Minnich; Chase, 1993).

Diante desse cenário, o presente estudo busca aprimorar a compreensão da dinâmica espacial dos incêndios florestais em todo o estado de Mato Grosso, empregando o algoritmo MaxEnt e diferentes preditores ambientais para identificar áreas de maior propensão ao fogo em condições presentes e sob os cenários SSP1-2.6 e SSP5-8.5, contribuindo para o planejamento de estratégias de prevenção, combate e gestão sustentável do território. De forma específica, buscou-se:

1.1 OBJETIVOS ESPECÍFICOS

a) ajustar e selecionar um modelo MaxEnt parcimonioso da propensão ao fogo, a partir de preditores bioclimáticos e topográficos, e avaliar seu desempenho em dados independentes;
b) identificar os principais preditores e a forma de sua relação com a propensão ao fogo;
c) mapear a propensão ao fogo nas condições presentes e delimitar as áreas de alta propensão;
d) projetar a propensão para 2021–2040 sob os cenários SSP1-2.6 e SSP5-8.5 e quantificar as mudanças de área por classe de propensão;
e) avaliar a incerteza entre os modelos climáticos MIROC6 e HadGEM3-GC31-LL.

2 REFERENCIAL TEÓRICO

2.1 FATORES AMBIENTAIS DO FOGO E MODELAGEM DE PROPENSÃO

A propensão ao fogo resulta da coincidência entre combustível, condições meteorológicas favoráveis e fontes de ignição, de modo que modelos que usam apenas variáveis ambientais estimam a adequação do ambiente ao fogo, e não a probabilidade de ignição (White *et al.*, 2016). No Brasil, a ignição é majoritariamente antrópica, mas a extensão e a severidade dos eventos dependem do regime de seca e da disponibilidade de combustível, o que torna a sazonalidade climática um condicionante central (Pivello *et al.*, 2021). No Cerrado e no chamado Arco do Desmatamento, a mudança climática de origem antrópica já foi associada a condições meteorológicas mais propícias ao fogo (Li *et al.*, 2021), e na Amazônia a fragmentação florestal associada ao desmatamento aumenta a exposição da floresta ao fogo (Silva Junior *et al.*, 2018). No Pantanal, os grandes incêndios de 2020 foram associados à ocorrência conjunta de seca e ondas de calor (Libonati *et al.*, 2022), processo episódico que médias climáticas de longo prazo não representam diretamente.

2.2 MAXENT, CENÁRIOS CLIMÁTICOS E INCERTEZA

O MaxEnt estima a distribuição de máxima entropia compatível com as restrições impostas pelas variáveis ambientais nos locais de presença, frente a uma amostra de pontos de fundo (*background*) (Phillips; Anderson; Schapire, 2006), e pode ser interpretado como um modelo de processo pontual com regularização (Elith *et al.*, 2011). A implementação *maxnet* produz a saída *cloglog* (Phillips *et al.*, 2017), usada neste estudo. O desempenho do MaxEnt é sensível à complexidade do modelo, definida pelas classes de feição e pelo multiplicador de regularização, o que motiva o ajuste sistemático desses parâmetros (Merow; Smith; Silander, 2013; Radosavljevic;

Anderson, 2014). Para avaliação, o TSS combina sensibilidade e especificidade e, ao contrário do *kappa*, não depende da prevalência (Allouche; Tsoar; Kadmon, 2006).

As projeções futuras usam variáveis bioclimáticas de modelos do CMIP6 (Eyring *et al.*, 2016), sob trajetórias socioeconômicas compartilhadas (SSP) definidas no ScenarioMIP (O'Neill *et al.*, 2016). Como diferentes modelos climáticos globais produzem campos de temperatura distintos, a variação entre eles é uma fonte de incerteza que deve ser quantificada, e a transferência do modelo para condições fora do intervalo de calibração exige avaliar a extrapolação, por exemplo com a superfície MESS (Elith; Kearney; Phillips, 2010).

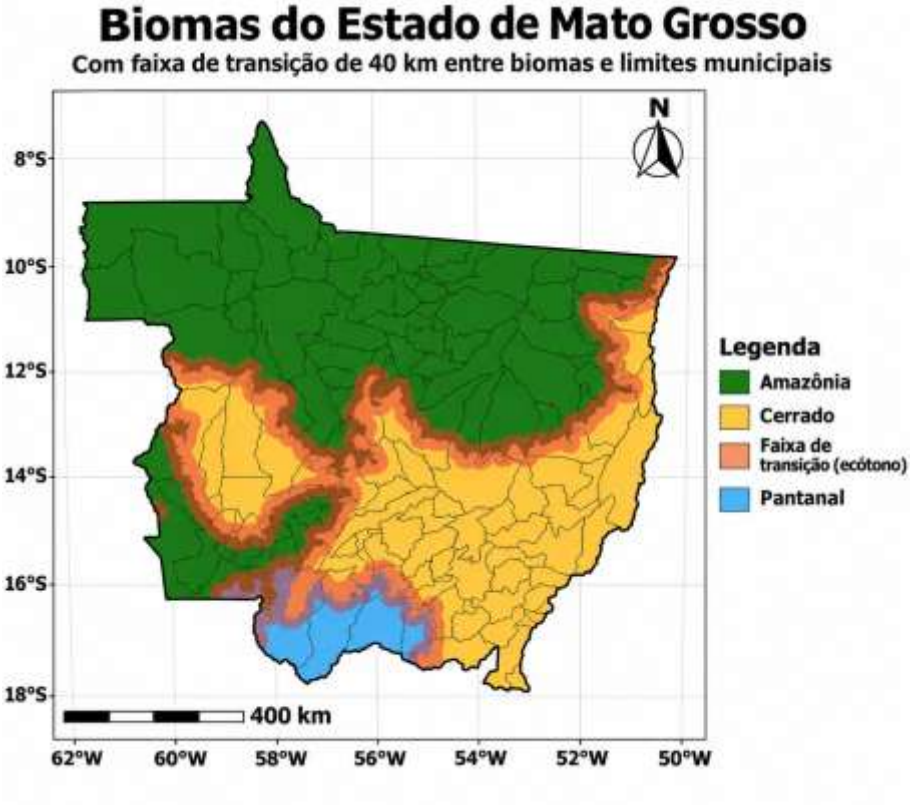
3 METODOLOGIA

3.1 ÁREA DE ESTUDO

A área de estudo compreende o estado de Mato Grosso, localizado na região Centro-Oeste do Brasil (Figura 1). O território mato-grossense possui aproximadamente 900 mil km² e apresenta ampla heterogeneidade ambiental, climática e de uso e cobertura da terra. Sua extensão territorial abrange aproximadamente as latitudes 7° S a 18° S e as longitudes 62° W a 52° W (Versieux; Costa, 2024). Essa amplitude espacial contribui para a ocorrência de importantes gradientes ambientais no território estadual, aspecto particularmente relevante para análises espaciais envolvendo clima, vegetação, mudanças no uso da terra e ocorrência de incêndios.

Mato Grosso apresenta uma característica biogeográfica especialmente importante para este estudo: seu território compreende áreas pertencentes a três grandes biomas brasileiros: Amazônia, Cerrado e Pantanal. A porção norte está associada principalmente ao domínio amazônico, enquanto áreas centrais e meridionais abrangem extensas formações do Cerrado e, no sudoeste, encontra-se a porção mato-grossense do Pantanal. Essa configuração resulta em elevada heterogeneidade de formações vegetacionais, condições hidrológicas e regimes ecológicos dentro de uma mesma unidade político-administrativa. O Instituto Brasileiro de Geografia e Estatística (IBGE) reconhece Amazônia, Cerrado e Pantanal entre os seis biomas continentais brasileiros e utiliza características de vegetação, geologia, geomorfologia, pedologia e clima na definição desses recortes territoriais (IBGE, 2025).

Figura 1. Distribuição espacial dos biomas (Amazônia, Cerrado e Pantanal) e da faixa de transição entre biomas (ecótono, com 40 km, conforme indicado no mapa original) no estado de Mato Grosso, Brasil, com limites municipais.



Fonte: IBGE (2025), camada de biomas (versão de 2019 informada pelos autores) e malha municipal de 2020 (pacote geobr). Elaboração: os autores.

O estado apresenta importante zona de transição entre formações amazônicas e savânicas. Estudos realizados em Mato Grosso descrevem a presença de florestas de transição entre as formações do Cerrado, na região central, e as florestas tropicais mais úmidas ao norte, enquanto a porção meridional inclui ambientes associados ao Pantanal e à dinâmica sazonal de inundação (D'Acunha *et al.*, 2024). Essa heterogeneidade ambiental implica respostas distintas da vegetação às variações sazonais de disponibilidade hídrica, temperatura e precipitação, fatores diretamente relacionados às condições de ocorrência e propagação do fogo.

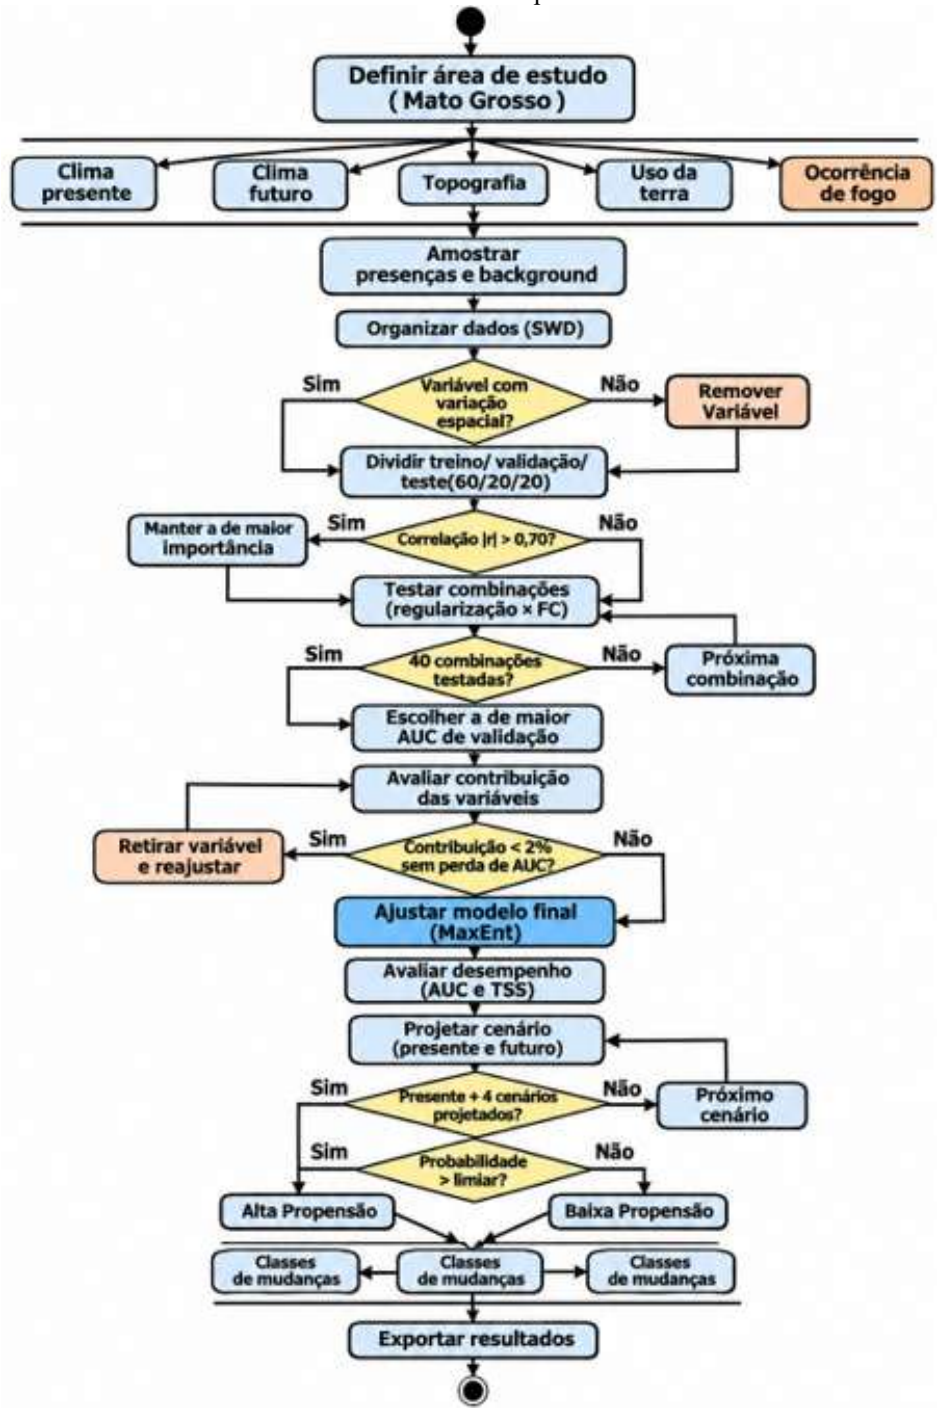
O clima de Mato Grosso é predominantemente tropical e apresenta marcada sazonalidade pluviométrica. Segundo a classificação climática de Köppen-Geiger, destacam-se principalmente condições do tipo Am, associadas ao clima tropical de monção e mais presentes ao norte, e Aw, caracterizado pelo clima tropical com inverno seco e predominante em grande parte das áreas centro-sul do estado. O regime climático apresenta uma estação chuvosa e outra seca bem definida, além de gradientes espaciais de precipitação e duração da estação seca. Os maiores totais pluviométricos são registrados ao norte, enquanto a duração da estação seca tende a aumentar em direção ao sul (D'Acunha *et al.*, 2024; Versieux; Costa, 2024).

A sazonalidade das chuvas constitui um componente ambiental especialmente importante para a dinâmica do fogo. Análises realizadas em ecossistemas de Mato Grosso indicam que aproximadamente 90% da precipitação anual nos locais avaliados ocorre durante a estação úmida, definida no estudo entre outubro e abril. A estação seca apresenta duração variável entre os diferentes ambientes, alcançando aproximadamente quatro a cinco meses nos sítios amazônicos analisados e cinco a seis meses nos sítios de Cerrado e Pantanal. Essa alternância entre períodos úmidos e secos modifica a disponibilidade hídrica e as condições da vegetação ao longo do ano, devendo ser considerada na interpretação da distribuição temporal e espacial dos incêndios (Biudes *et al.*, 2022).

3.2 DADOS E PRÉ-PROCESSAMENTO

O processamento, a análise espacial e a modelagem foram realizados no ambiente RStudio, utilizando a versão 4.5.1 do R (Figura 2). O fluxo analítico foi implementado principalmente por meio dos pacotes *terra*, *geodata*, *geobr*, *sf*, *SDMtune*, *predicts*, *dplyr*, *tidyr*, *ggplot2*, *tidyterra*, *ggspatial* e *writexl*. Para garantir a reprodutibilidade das etapas que envolveram procedimentos aleatórios, foi definida a semente 25 (*set.seed* = 25).

Figura 2. Fluxograma metodológico da modelagem espacial da propensão à ocorrência de incêndios florestais em Mato Grosso sob cenários climáticos presentes e futuros.



Fonte: Elaborado pelos autores, 2026

A modelagem da ocorrência de fogo no estado de Mato Grosso foi realizada utilizando o algoritmo MaxEnt, implementado pelo método *Maxnet* no pacote *SDMtune* (Vignali *et al.*, 2020). Foram integrados três grupos principais de variáveis preditoras: variáveis bioclimáticas, topográficas e de uso e cobertura da terra. Os registros de ocorrência de fogo foram derivados de dados do MapBiomas Fogo (Alencar *et al.*, 2022), produto baseado em imagens Landsat; o período temporal

dos registros de área queimada utilizados não foi informado pelos autores. Para as projeções futuras, foram considerados dois modelos climáticos globais, MIROC6 e HadGEM3-GC31-LL, sob os cenários SSP1-2.6 e SSP5-8.5, para o período de 2021–2040.

O limite territorial de Mato Grosso foi obtido por meio do pacote *geobr*, considerando a malha estadual referente ao ano de 2020, posteriormente projetada para o sistema de referência geográfica EPSG:4326. As variáveis climáticas do período presente foram obtidas da base WorldClim 2.1 (Fick; Hijmans, 2017), contemplando as 19 variáveis bioclimáticas (BIO1–BIO19), com resolução espacial de 2,5 minutos de arco (cerca de 4,6 km no equador). Essa base descreve médias climáticas históricas (1970–2000, segundo seus autores), de modo que o termo “presente” refere-se à linha de base climática, e não ao clima do período dos registros de fogo. As camadas foram recortadas e mascaradas segundo os limites da área de estudo, sendo posteriormente utilizadas como referência espacial para compatibilização das demais variáveis.

Para a representação das condições climáticas futuras, foram obtidas as mesmas 19 variáveis bioclimáticas provenientes do CMIP6 (Eyring *et al.*, 2016), considerando os modelos MIROC6 e HadGEM3-GC31-LL e os cenários de emissão SSP1-2.6 e SSP5-8.5 (O'Neill *et al.*, 2016). As projeções corresponderam ao período de 2021–2040 e foram recortadas para Mato Grosso, reamostradas pelo método bilinear e ajustadas à mesma grade espacial utilizada para as condições climáticas presentes.

As variáveis topográficas foram representadas pela elevação e declividade, derivadas de dados do SRTM. A declividade foi calculada em graus a partir do modelo digital de elevação. Ambas as variáveis foram reamostradas e compatibilizadas com a resolução espacial da grade climática utilizada na modelagem.

Os dados de uso e cobertura da terra foram organizados em oito grupos: floresta, savana, formação campestre, pastagem, agricultura, mosaico de usos, áreas não vegetadas e água. Para cada grupo foi calculada sua proporção por célula da grade utilizada na modelagem, permitindo incorporar ao modelo a composição da paisagem como conjunto de variáveis preditoras. A fonte desses dados não é indicada no texto original; a lista de referências original inclui a Coleção 11 do MapBiomas (MapBiomas, 2026), que provavelmente lhes corresponde. As ocorrências de fogo foram derivadas dos dados *raster* do MapBiomas Fogo. Inicialmente, as células contendo registros de área queimada foram convertidas em uma representação binária e, posteriormente, agregadas à grade espacial da modelagem. Foi calculada a fração queimada de cada célula, considerando-se como ocorrência de fogo aquelas que apresentaram fração queimada igual ou superior a 5%. O número máximo de pontos de

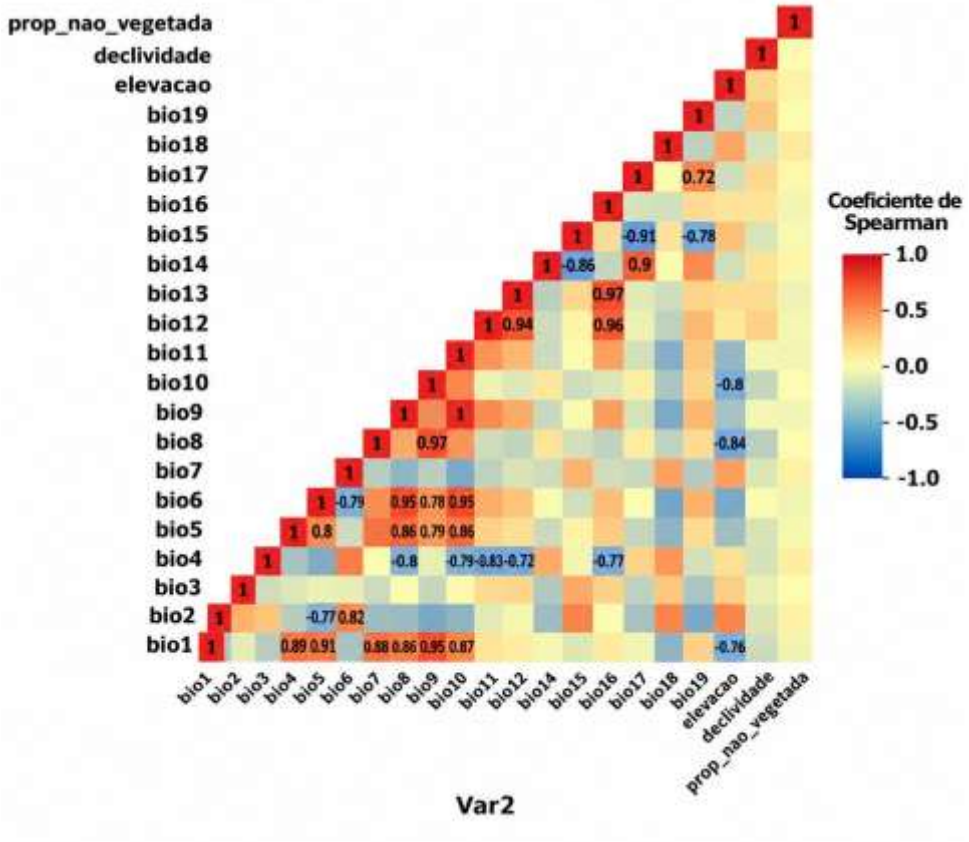
presença foi limitado a 5.000, enquanto 10.000 pontos de *background* foram amostrados aleatoriamente na área de estudo.

3.3 AJUSTE E SELEÇÃO DO MODELO

Após a preparação dos dados, as ocorrências e variáveis ambientais foram organizadas no formato SWD (*Sample With Data*) por meio da função *prepareSWD* do pacote *SDMtune*. Antes da modelagem, variáveis sem variação espacial relevante dentro da área de estudo foram removidas. O conjunto de dados foi então dividido em 60% para treinamento, 20% para validação e 20% para teste, utilizando a função *trainValTest*, com semente aleatória igual a 25. O conjunto de validação foi destinado à seleção e otimização do modelo, enquanto o conjunto de teste foi reservado para sua avaliação final. Como a divisão foi aleatória (não espacialmente estratificada), amostras vizinhas podem aparecer em conjuntos distintos, o que pode superestimar o desempenho.

Foi ajustado um modelo MaxEnt pelo método *Maxnet*. A seleção das variáveis preditoras foi realizada por meio da função *varSel*, considerando a correlação de Spearman e um limiar de correlação absoluta de $r > 0,70$, de modo a reduzir a redundância entre os preditores. A seleção considerou a AUC como métrica de desempenho e 1.000 permutações para estimar a importância relativa das variáveis. A matriz de correlação das variáveis também foi calculada e representada graficamente (Figura 3).

Figura 3. Matriz de correlação de Spearman entre as 22 variáveis preditoras candidatas (19 bioclimáticas, elevação, declividade e proporção de área não vegetada). São exibidos apenas os coeficientes com |r| > 0,70.



Fonte: Elaborado pelos autores, 2026

Após a seleção inicial das variáveis, foi realizada uma busca sistemática de hiperparâmetros (*grid search*), testando 40 combinações resultantes de oito valores do multiplicador de regularização (0,5; 1; 1,5; 2; 2,5; 3; 3,5 e 4) e cinco configurações de *feature classes* (L, LQ, LH, LQH e LQHP). As combinações foram comparadas com base na AUC obtida no conjunto de validação e na diferença entre as AUCs, selecionando-se a configuração de melhor desempenho.

Foi aplicada uma etapa de redução de variáveis por meio da função *reduceVar*, utilizando um limite mínimo de 2% de contribuição, AUC como métrica, teste *jackknife* e 1.000 permutações. Após a definição das variáveis e dos hiperparâmetros finais, os conjuntos de treinamento e validação foram combinados para o ajuste definitivo do modelo. O conjunto de teste permaneceu independente e foi utilizado exclusivamente para avaliar o desempenho final.

3.4 AVALIAÇÃO, LIMIAR E PROJEÇÕES

O desempenho preditivo foi avaliado por meio da área sob a curva ROC (AUC) e do *True Skill Statistic* (TSS) (Allouche; Tsoar; Kadmon, 2006), calculados para os conjuntos de treinamento e teste. Também foi examinada a diferença entre os valores obtidos nesses conjuntos. A contribuição das

variáveis foi investigada por meio da importância por permutação, com 1.000 permutações, e de análises *jackknife* baseadas na AUC. Foram produzidas curvas de resposta para as variáveis mantidas no modelo final.

Para converter as probabilidades contínuas de ocorrência em classes binárias, foi adotado o limiar correspondente ao critério "*Maximum test sensitivity plus specificity*", obtido a partir das previsões em escala *cloglog*. Esse limiar foi utilizado para distinguir áreas de baixa e alta propensão à ocorrência de fogo.

O modelo final foi projetado tanto para as condições ambientais presentes quanto para os quatro cenários futuros resultantes da combinação entre os dois modelos climáticos globais e os dois SSPs. Para cada SSP, também foi calculada a média das projeções dos dois modelos climáticos, enquanto o desvio-padrão entre os GCMs foi utilizado como medida da variabilidade entre suas projeções. Nas projeções futuras, as variáveis topográficas e de uso e cobertura da terra foram mantidas constantes, sendo modificadas apenas as condições climáticas.

A partir da comparação entre as projeções presentes e futuras, foram identificadas quatro classes de mudança: baixa propensão persistente, aumento da propensão, redução da propensão e alta propensão persistente. Para cada classe, foram calculadas a área ocupada, em km², e sua participação percentual em cada cenário. Adicionalmente, as probabilidades foram agrupadas em quatro classes de propensão ao fogo: baixa (0–0,25), moderada (0,25–0,50), alta (0,50–0,75) e muito alta (0,75–1,00), permitindo comparar quantitativamente a extensão territorial das diferentes classes entre o presente e os cenários futuros.

Foi aplicada a análise MESS (*Multivariate Environmental Similarity Surface*) (Elith; Kearney; Phillips, 2010) às projeções futuras, utilizando como referência as condições ambientais empregadas no treinamento do modelo, com o objetivo de representar espacialmente condições de extrapolação ambiental. Os resultados foram exportados na forma de *rasters*, mapas temáticos, figuras e planilhas, incluindo métricas de avaliação, etapas de seleção do modelo, resultados da busca de hiperparâmetros, importância das variáveis, *jackknife*, limiares, áreas das classes de propensão, mudanças espaciais e probabilidades médias dos diferentes cenários. Os resultados do MESS, contudo, não são apresentados neste manuscrito.

4 RESULTADOS E DISCUSSÃO

4.1 DESEMPENHO E PARCIMÔNIA DO MODELO

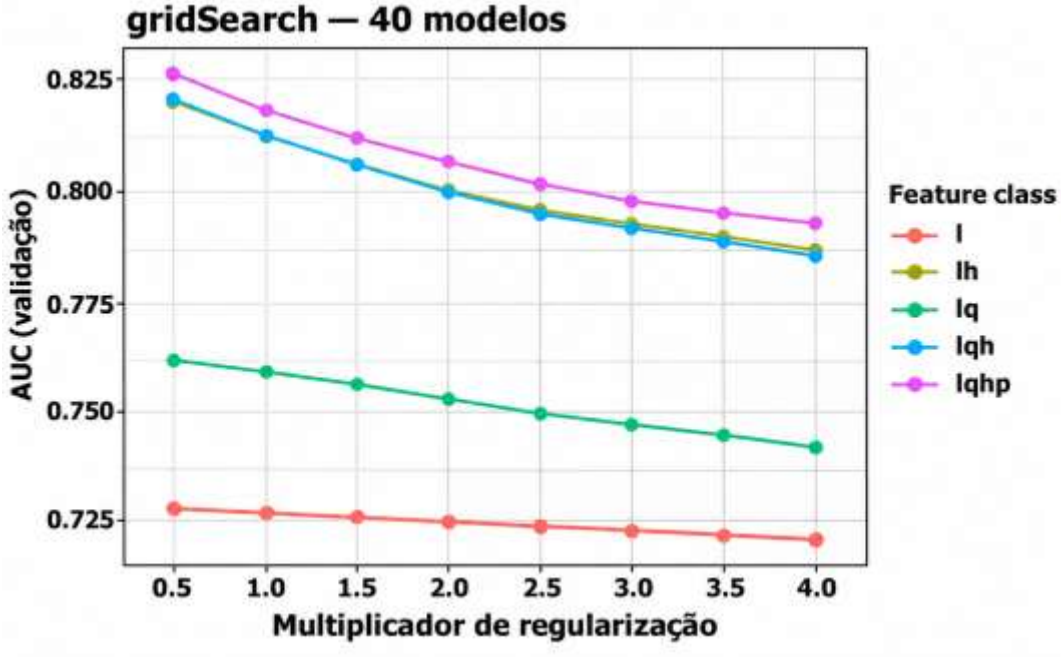
A modelagem da propensão ao fogo em Mato Grosso apresentou desempenho preditivo satisfatório e relativa estabilidade ao longo das diferentes etapas de calibração, mesmo após a redução

progressiva do número de variáveis. O modelo inicial foi construído com 22 preditores, incluindo 19 variáveis bioclimáticas, elevação, declividade e proporção de área não vegetada. Após o controle da colinearidade, a seleção de variáveis, o ajuste dos hiperparâmetros e a simplificação final, foram mantidas nove variáveis, com classes de feição linear, *quadratic*, *hinge* e *product* (lqhp) e multiplicador de regularização igual a 0,5 (Figura 4). Esse processo reduziu a complexidade do conjunto preditor sem comprometer substancialmente a capacidade discriminatória do modelo, uma vez que a AUC de teste variou de 0,832 no modelo inicial para 0,830 no modelo final.

A redução das variáveis correlacionadas ocasionou uma diminuição inicial da AUC de teste, de aproximadamente 0,832 para 0,818, mas também reduziu a diferença entre os valores obtidos no treinamento e no teste. O ajuste dos hiperparâmetros recuperou parte desse desempenho, elevando a AUC de teste para aproximadamente 0,826. A exclusão da variável referente à proporção de área não vegetada produziu alteração praticamente desprezível na AUC, que passou de 0,8264 para 0,8266. Esse resultado indica que, no conjunto analisado, a retirada dessa variável pouco afetou a capacidade discriminatória do modelo. Ao mesmo tempo, sua exclusão permitiu que as projeções futuras fossem realizadas exclusivamente com variáveis climáticas e topográficas, evitando a necessidade de incorporar cenários futuros de uso e cobertura da terra.

A busca de hiperparâmetros também demonstrou a importância da flexibilidade funcional na representação da relação entre as condições ambientais e a propensão ao fogo. As configurações contendo a feição *hinge* apresentaram desempenho superior às combinações mais simples, enquanto modelos restritos principalmente às feições linear e quadrática alcançaram valores inferiores aos de AUC. A configuração lqhp com regularização de 0,5 apresentou o melhor resultado entre os 40 modelos avaliados, com AUC de teste de aproximadamente 0,826. Esse comportamento sugere que as relações capturadas pelo modelo não são adequadamente representadas apenas por respostas lineares simples, sendo necessária maior flexibilidade para descrever variações na propensão ao fogo ao longo dos gradientes ambientais. Entretanto, como o melhor multiplicador de regularização correspondeu ao menor valor testado (0,5), permanece a possibilidade de que valores inferiores pudessem resultar em configurações alternativas. A seleção foi orientada principalmente pela AUC, de modo que a inclusão de critérios adicionais de avaliação poderia alterar a escolha do modelo ótimo.

Figura 4. AUC de validação dos 40 modelos testados na busca de hiperparâmetros, segundo o multiplicador de regularização e a combinação de classes de feição (l = linear; q = quadrática; h = hinge; p = product).



Fonte: Elaborado pelos autores, 2026

O modelo final apresentou AUC de 0,8374 para treinamento e 0,8303 para teste, com diferença de apenas 0,0071 entre os conjuntos (Figura 5a e Tabela 1). Os valores de TSS foram igualmente próximos, correspondendo a 0,5369 no treinamento e 0,5386 no teste. A pequena diferença entre treinamento e teste indica estabilidade da capacidade discriminatória quando o modelo é aplicado a dados não utilizados diretamente em seu ajuste, sem evidência expressiva de sobreajuste. Em contrapartida, o TSS em torno de 0,54 indica que ainda existe uma parcela considerável da variabilidade que não é capturada pelo conjunto de preditores empregado. Essa limitação é particularmente relevante para a modelagem do fogo, uma vez que o modelo final é constituído apenas por variáveis climáticas e topográficas e, portanto, não representa diretamente fatores antrópicos relacionados à ocorrência de ignições, mudanças no uso da terra e outras intervenções humanas.

Tabela 1. Métricas de desempenho do modelo MaxEnt final nos conjuntos de treinamento e teste.

Métrica	Treinamento	Teste	Diferença
AUC	0,8374	0,8303	0,0071
TSS	0,5369	0,5386	–

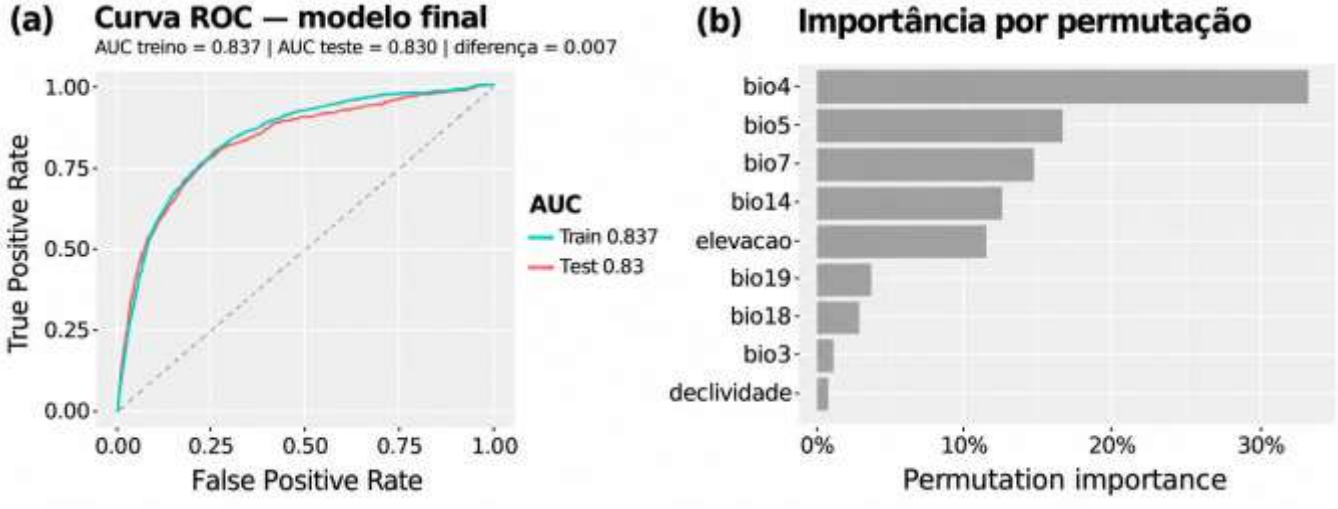
Fonte: Elaborada pelos autores (2026), a partir dos resultados informados no manuscrito original.

4.2 IMPORTÂNCIA DAS VARIÁVEIS E CURVAS DE RESPOSTA

A análise da importância das variáveis evidencia a predominância dos componentes térmicos na estrutura preditiva do modelo (Figura 5b). A sazonalidade da temperatura (bio4) apresentou a maior importância por permutação, com 32,9%, seguida pela temperatura máxima do mês mais quente (bio5),

com 17,4%, e pela amplitude térmica anual (bio7), com 15,6%. Em conjunto, essas três variáveis representam aproximadamente dois terços da importância por permutação atribuída pelo modelo. Entre os componentes associados à precipitação, destacou-se a precipitação do mês mais seco (bio14), com 13,6%, enquanto bio19 e bio18 apresentaram contribuições de 3,6% e 2,8%, respectivamente. A elevação também apresentou participação relevante, com 12,6%, ao passo que bio3 e declividade tiveram importância reduzida, de 0,9% e 0,6%.

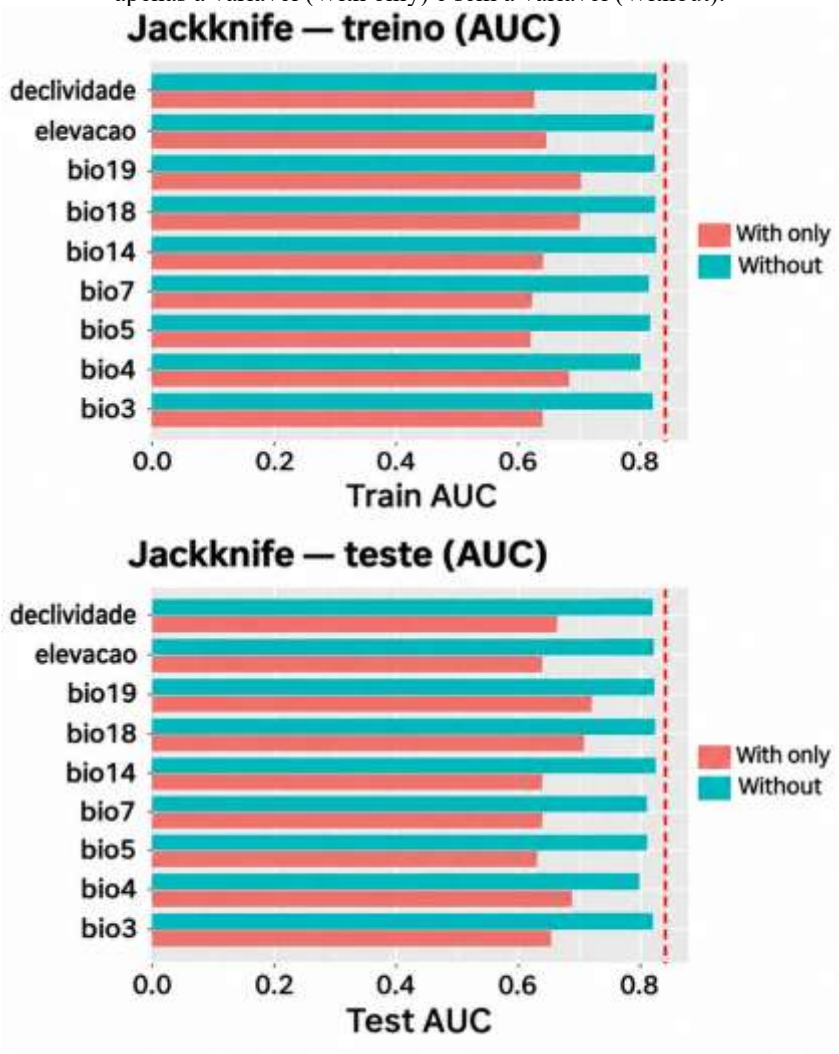
Figura 5. Desempenho e importância das variáveis do modelo final: (a) curva ROC para os conjuntos de treinamento (AUC = 0,837) e teste (AUC = 0,830); (b) importância por permutação (%) das nove variáveis mantidas no modelo final.



Fonte: Elaborado pelos autores, 2026

Os resultados do jackknife complementam essa interpretação ao mostrar que diferentes métricas de importância fornecem informações distintas sobre a contribuição dos preditores (Figura 6). A remoção de bio4 ocasionou a maior redução da AUC de teste, que passou de aproximadamente 0,830 para 0,810, reforçando a existência de informação particularmente relevante associada à sazonalidade térmica. Por outro lado, bio19 e bio18 apresentaram AUC de 0,709 e 0,702 quando utilizadas isoladamente, respectivamente, apesar de sua menor importância por permutação. Isso indica que essas variáveis possuem capacidade preditiva individual, mas parte da informação que carregam pode estar compartilhada com outros componentes ambientais presentes no modelo. Em contraste, a retirada da declividade praticamente não modificou a AUC de teste, que permaneceu em aproximadamente 0,830, enquanto a retirada de bio3 resultou em AUC próxima de 0,829. Esses resultados sugerem contribuição adicional limitada dessas duas variáveis no conjunto final.

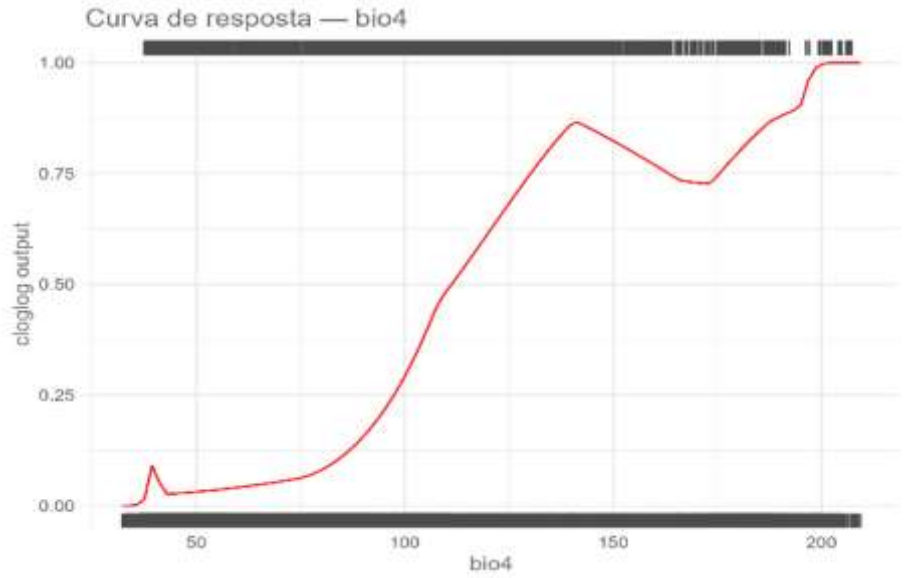
Figura 6. Teste jackknife da contribuição das variáveis com base na AUC: (a) conjunto de treinamento (painel superior); (b) conjunto de teste (painel inferior). A linha tracejada indica a AUC do modelo completo; as barras indicam a AUC com apenas a variável (With only) e sem a variável (Without).



Fonte: Elaborado pelos autores, 2026

Os resultados apontam para uma associação importante entre a propensão ao fogo e a variabilidade térmica, os extremos de temperatura e as condições de precipitação relacionadas aos períodos mais secos. Essa configuração é compatível com a forte sazonalidade climática existente em diferentes porções de Mato Grosso e com a relevância da estação seca para a dinâmica regional do fogo. A importância de uma variável no modelo não permite, isoladamente, estabelecer a direção de seu efeito. Para essa interpretação, é necessário examinar as curvas de resposta das variáveis (Figura 7).

Figura 7. Curva de resposta (saída cloglog) da sazonalidade da temperatura (bio4, desvio-padrão × 100). As marcas na parte superior e inferior do gráfico indicam a distribuição dos pontos de presença e de fundo ao longo do gradiente.



Fonte: Elaborado pelos autores, 2026

A curva de resposta de bio4 (Figura 7) indica que a relação entre a propensão ao fogo e a sazonalidade da temperatura é positiva, porém não linear. Para a sazonalidade da temperatura (bio4, desvio-padrão × 100), a propensão permanece próxima de zero até valores em torno de 80, cresce de forma acentuada entre aproximadamente 90 e 140, atinge um primeiro máximo próximo de 0,87, sofre leve redução entre cerca de 150 e 175 e volta a aumentar, aproximando-se de 1,0 acima de 195. Para a temperatura máxima do mês mais quente (bio5), os autores descrevem resposta baixa até cerca de 31 °C, aumento gradual até 33,5 °C e inflexão abrupta entre 33,5 °C e 34,5 °C, com valores próximos de 1,0 entre 35 °C e 35,5 °C e declínio leve acima desse intervalo; essa curva, porém, não consta na figura submetida. Esse comportamento sugere a existência de um limiar térmico, a partir do qual pequenos acréscimos na temperatura máxima produzem grandes incrementos na propensão, aspecto central para a interpretação das projeções futuras, embora dependa de uma curva que deve ser exibida para verificação.

A isotermalidade (bio3), por sua vez, apresenta, segundo a descrição original, curva irregular, com sucessivos picos e vales e um aumento abrupto no extremo superior do gradiente, onde há poucos registros. Considerando sua baixa importância por permutação (0,9%), esse padrão deve ser interpretado com cautela, pois provavelmente reflete a flexibilidade conferida pelas feições hinge e pelo baixo multiplicador de regularização (0,5), e não uma relação ecológica bem definida.

4.3 LIMIAR DE CLASSIFICAÇÃO E PADRÃO ESPACIAL PRESENTE

Outro componente importante da modelagem refere-se à definição do limiar utilizado para converter as probabilidades contínuas em classes (Tabela 2). O limiar selecionado foi de 0,420638 na saída *cloglog*, associado à maximização do desempenho no conjunto de teste. Com esse valor, aproximadamente 22,8% da área analisada foi classificada acima do limiar. Em comparação, o critério de presença mínima de treinamento apresentou limiar extremamente baixo, de aproximadamente 0,0044, resultando na classificação de quase toda a área como adequada e, consequentemente, oferecendo pouca capacidade de diferenciação espacial. O limiar associado à maximização do desempenho no treinamento foi de aproximadamente 0,3623 e classificou cerca de 26,6% da área acima do corte.

Tabela 2. Limiares de classificação avaliados (saída cloglog) e proporção da área classificada acima do corte.

Critério	Limiar	Área acima do limiar (%)
Máxima sensibilidade + especificidade no teste (adotado)	0,4206	22,8
Máxima sensibilidade + especificidade no treinamento	0,3623	26,6
Presença mínima de treinamento	0,0044	quase toda a área

Fonte: Elaborada pelos autores (2026), a partir dos resultados informados no manuscrito original.

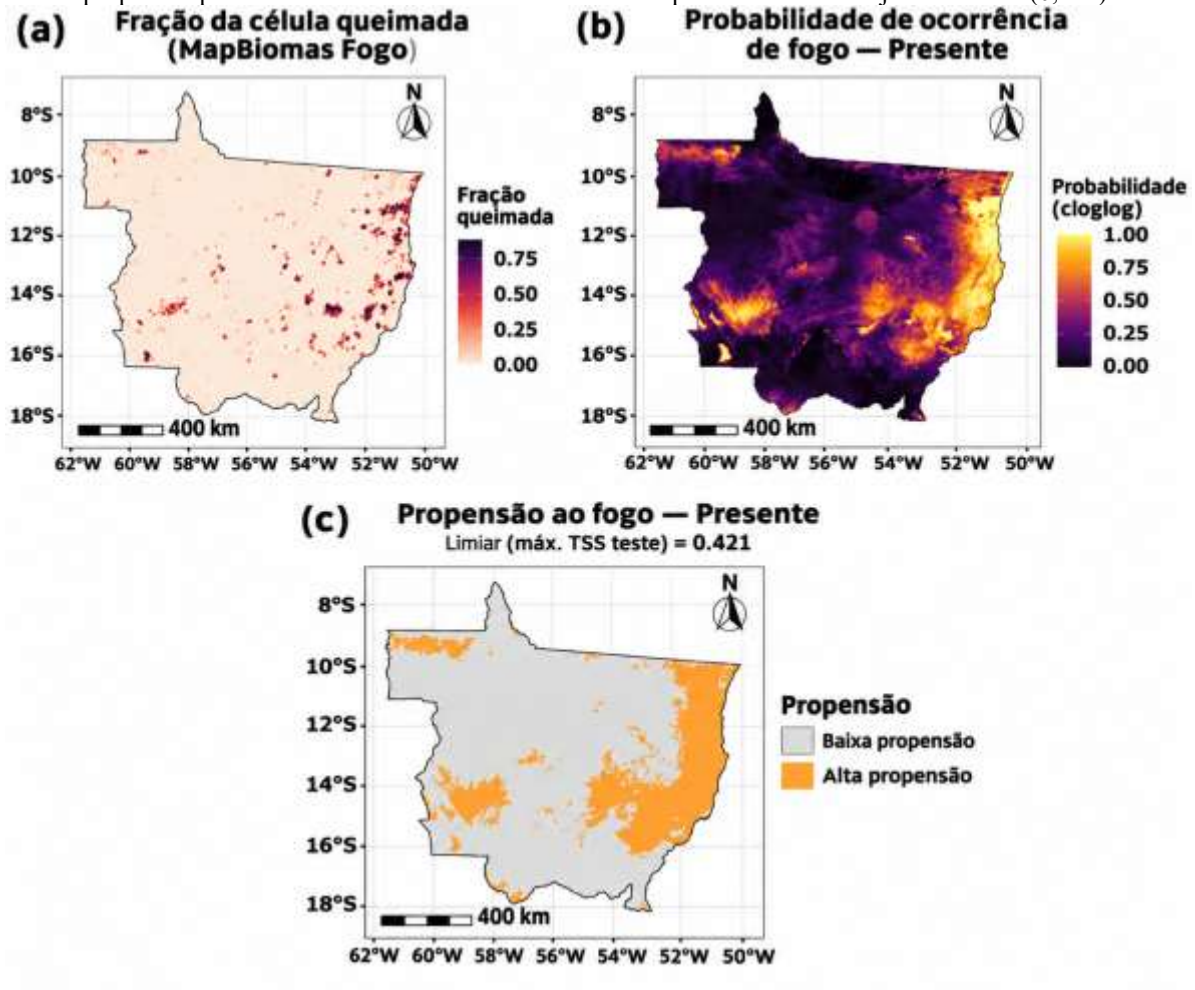
A utilização do próprio conjunto de teste para selecionar o limiar, entretanto, exige cautela. Como esses dados também participam da escolha do ponto de corte, a avaliação resultante pode ser parcialmente otimista. Além disso, as taxas de omissão registradas para o limiar selecionado (aproximadamente 24,2% no treinamento e 1,2% no teste) não parecem plenamente compatíveis com os demais indicadores de desempenho, o que pode indicar que as métricas foram calculadas a partir de partições ou procedimentos diferentes. Por essa razão, essas taxas não foram usadas para sustentar conclusões neste trabalho.

A distribuição espacial das ocorrências de fogo e da propensão estimada para as condições presentes é apresentada na Figura 8. As maiores frações de área queimada concentram-se na porção leste do estado, sobretudo ao longo do Vale do Araguaia e no setor compreendido entre 51° W e 54° W e entre 11° S e 15° S, áreas inseridas predominantemente no Cerrado e na faixa de transição entre Amazônia e Cerrado (Figura 1). Agrupamentos menores ocorrem no oeste, na região da Chapada dos Parecis (em torno de 58,5° W e 14,5° S), no extremo sudoeste, junto à fronteira com a Bolívia, e no noroeste, em domínio amazônico. Em contrapartida, o núcleo florestal do norte do estado e a planície pantaneira apresentam frações queimadas muito reduzidas (Figura 8a).

A probabilidade estimada pelo modelo (Figura 8b) reproduz esse padrão geral. Valores superiores a 0,75 formam um corredor praticamente contínuo ao longo da borda leste, que se estende em direção aos planaltos do centro-sul, e um segundo núcleo no oeste, sobre a Chapada dos Parecis e

a transição com a Amazônia, aproximadamente entre 58° W e 60,5° W e entre 13,5° S e 15,5° S. Probabilidades moderadas a altas também aparecem no extremo noroeste (entre 9° S e 9,5° S e entre 59° W e 61,5° W), região amazônica que pode estar sujeita à pressão de desmatamento, hipótese que não foi testada neste estudo. Já o setor amazônico centro-norte, entre 9,5° S e 12° S e entre 54° W e 58° W, apresenta probabilidades próximas de zero, assim como a maior parte do Pantanal e a faixa amazônica do sudoeste. A aplicação do limiar de 0,421 (Figura 8c) delimita esses núcleos como áreas de alta propensão, que correspondem a cerca de 22,8% da área analisada e se concentram essencialmente no Cerrado e nas zonas de transição.

Figura 8. Ocorrência e propensão ao fogo no presente em Mato Grosso: (a) fração da célula queimada (MapBiomas Fogo); (b) probabilidade de ocorrência de fogo estimada pelo modelo (saída cloglog); (c) classificação em baixa e alta propensão pelo limiar de máxima sensibilidade mais especificidade no conjunto de teste (0,421).



Fonte: MapBiomas Fogo; elaborada pelos autores (2026).

A correspondência entre os núcleos de alta propensão e o Cerrado é coerente com as curvas de resposta das variáveis térmicas. O Cerrado mato-grossense tende a apresentar maior sazonalidade térmica e temperaturas máximas mais elevadas durante a estação seca do que o núcleo amazônico, o

que o posiciona nos segmentos de maior inclinação das curvas de bio4 e bio5; essa explicação é uma inferência dos autores, não testada com os dados climáticos por bioma. Soma-se a isso a estrutura da vegetação: as formações savânicas e campestres acumulam biomassa herbácea fina, que perde umidade rapidamente durante a estiagem e constitui combustível altamente inflamável, e o fogo é um elemento recorrente desse bioma, tanto por causas naturais quanto pelo seu uso no manejo de pastagens e na abertura de áreas (Pivello *et al.*, 2021). No núcleo amazônico, ao contrário, a menor sazonalidade térmica, a elevada umidade do sub-bosque e a cobertura florestal contínua reduzem a inflamabilidade, de modo que a propensão climática estimada é baixa. Essa baixa propensão, contudo, não significa ausência de risco, uma vez que os incêndios na Amazônia estão fortemente associados ao desmatamento, à fragmentação florestal e ao uso do fogo em áreas convertidas (Silva Junior *et al.*, 2018; Aragão *et al.*, 2018), processos que não são representados diretamente no modelo final após a exclusão da proporção de área não vegetada.

O Pantanal requer atenção particular. Embora o bioma tenha registrado incêndios de grande magnitude em anos recentes (Libonati *et al.*, 2022), sua porção mato-grossense apresentou baixa fração queimada no conjunto de ocorrências utilizado e baixa probabilidade estimada para o presente. Esse resultado provavelmente decorre do fato de que o regime de fogo pantaneiro é condicionado sobretudo pelo pulso de inundação e pela ocorrência de anos de seca extrema, que alteram a disponibilidade de combustível de forma episódica. Esses processos não são captados por médias climáticas de longo prazo, como as variáveis bioclimáticas do WorldClim, e sua representação nos dados de ocorrência depende do período de referência adotado. Assim, a baixa propensão estimada para a planície pantaneira deve ser interpretada como uma limitação do modelo, e não como indicativo de baixo risco efetivo.

4.4 PROJEÇÕES PARA 2021–2040

As projeções para 2021–2040 apontam para mudanças expressivas na distribuição da propensão ao fogo em Mato Grosso (Tabela 3). A probabilidade média estimada para as condições presentes foi de 0,2755, enquanto a média entre os modelos climáticos atingiu 0,4920 no SSP1-2.6 e 0,4746 no SSP5-8.5. Esses valores correspondem a aumentos de aproximadamente 79% e 72%, respectivamente. Embora o SSP1-2.6 apresente valor ligeiramente superior ao SSP5-8.5 nesse horizonte temporal, essa diferença não deve ser interpretada como evidência de que o cenário de maiores emissões resultaria em menor propensão ao fogo. As diferenças entre os modelos climáticos empregados são maiores que aquelas observadas entre os dois cenários, evidenciando a influência da escolha do modelo climático sobre as projeções de curto prazo. Em consonância, estudos em escala

regional indicam que a mudança climática já eleva a probabilidade de condições meteorológicas propícias ao fogo no Cerrado (Li *et al.*, 2021), o que torna plausível a direção do resultado, sem validar sua magnitude.

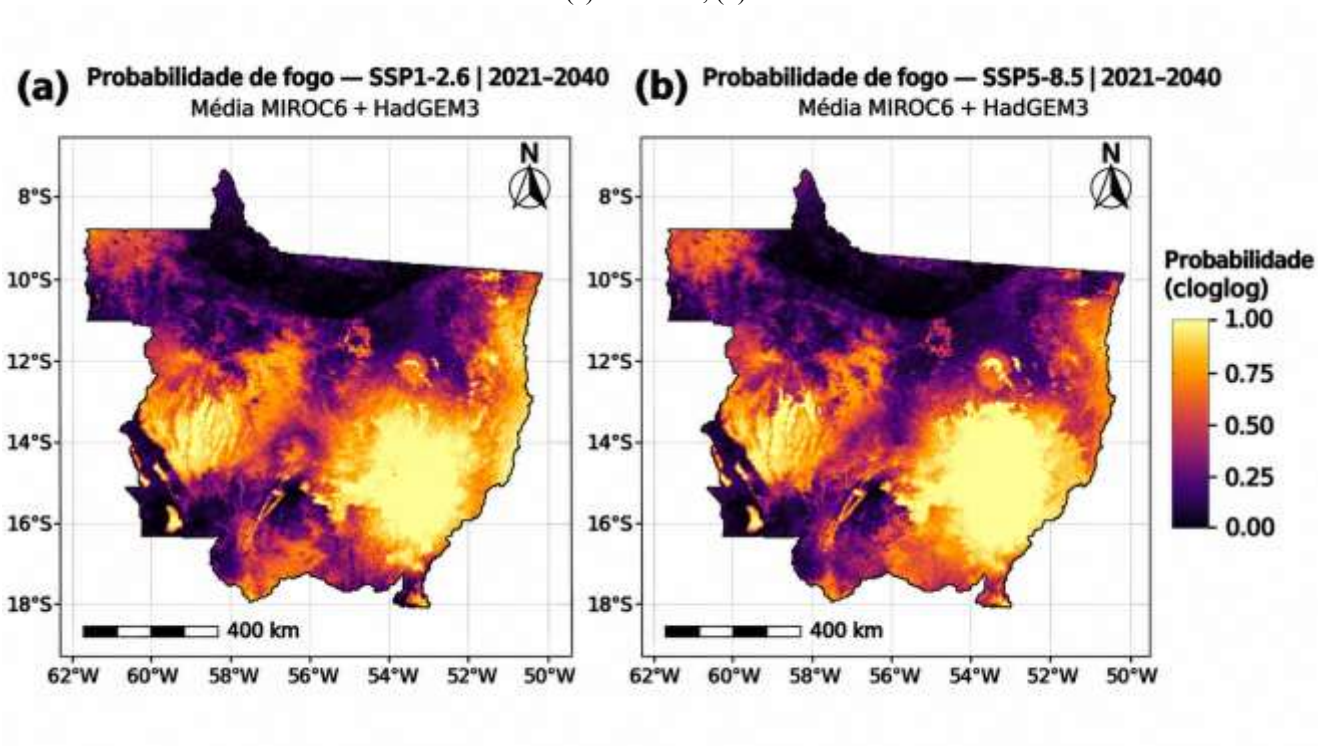
Tabela 3. Probabilidade média de ocorrência de fogo (saída cloglog) em Mato Grosso no presente e em 2021–2040, por cenário e modelo climático.

Cenário	Média dos modelos	MIROC6	HadGEM3-GC31-LL	Variação em relação ao presente (%)
Presente	0,2755	–	–	–
SSP1-2.6 (2021–2040)	0,4920	0,466	0,518	+79
SSP5-8.5 (2021–2040)	0,4746	0,445	0,504	+72

Fonte: Elaborada pelos autores (2026), a partir dos resultados informados no manuscrito original.

A Figura 9 mostra que o aumento da probabilidade média não se distribui de forma homogênea pelo território. Nos dois cenários, a média dos modelos climáticos indica a intensificação e a expansão do núcleo de alta propensão do centro-sul e do leste, com extensas áreas de probabilidade superior a 0,9 entre aproximadamente 52° W e 55° W e entre 13° S e 16,5° S, no domínio do Cerrado. O núcleo do oeste, sobre a Chapada dos Parecis e as áreas de transição com a Amazônia, também se intensifica. A principal mudança em relação ao presente é o avanço da propensão sobre a faixa de transição Amazônia–Cerrado, que se estende de oeste a leste entre 12° S e 14° S, e sobre o enclave amazônico do centro-oeste, áreas que no presente se encontravam majoritariamente na classe de baixa propensão. No SSP5-8.5, observa-se ainda maior propensão no extremo sul do estado, no planalto adjacente à borda do Pantanal. Em contraste, o núcleo amazônico do norte permanece com probabilidades baixas em todos os cenários, assim como a planície pantaneira e a faixa amazônica do sudoeste. Observam-se também feições lineares orientadas no sentido nordeste–sudoeste entre 56° W e 57,5° W e entre 14,5° S e 16° S, que acompanham as serras da Província Serrana e refletem a contribuição da elevação (12,6%) para o modelo.

Figura 9. Probabilidade de ocorrência de fogo projetada para 2021–2040, média dos modelos MIROC6 e HadGEM3-GC31-LL: (a) SSP1-2.6; (b) SSP5-8.5.



Fonte: Elaborado pelos autores, 2026

Uma explicação plausível para esse padrão espacial está no formato das curvas de resposta. Nas zonas de transição e no Cerrado do centro-sul, as temperaturas máximas atuais provavelmente se situam próximas do intervalo de maior inclinação da curva de bio5, entre 33,5 °C e 34,5 °C. O aquecimento projetado para 2021–2040 desloca essas células para a faixa de resposta máxima, produzindo aumentos expressivos de probabilidade mesmo com variações moderadas de temperatura. No núcleo amazônico, a baixa sazonalidade térmica mantém bio4 no segmento inicial da curva, onde a resposta é praticamente nula, de modo que o aquecimento esperado nesse horizonte não é suficiente para elevar substancialmente a propensão. Esse mecanismo de limiar ajuda a explicar por que as maiores mudanças se concentram nas zonas de transição entre biomas, onde as condições climáticas atuais encontram-se próximas dos pontos de inflexão das respostas do modelo. Trata-se, ademais, de áreas onde a fragmentação florestal e a conversão para usos agropecuários já ampliam a exposição ao fogo, embora o uso da terra tenha sido mantido constante nas projeções. Esse mecanismo é uma hipótese interpretativa, pois as temperaturas por célula não foram comparadas diretamente com as curvas de resposta neste estudo.

Essa tendência também é evidente na distribuição espacial das classes de propensão (Tabela 4). No cenário presente, aproximadamente 61,5% da área encontra-se na classe de baixa propensão, enquanto 19,4% corresponde à classe moderada, 10,3% à alta e 8,7% à muito alta. Nas projeções para

2021–2040, a classe de baixa propensão diminui para 30,4% no SSP1-2.6 e 34,3% no SSP5-8.5. Em sentido oposto, a classe de propensão muito alta aumenta de aproximadamente 80 mil km² no presente para cerca de 247 mil km² no SSP1-2.6 e 224 mil km² no SSP5-8.5, correspondendo, respectivamente, a 26,9% e 24,5% da área analisada. Quando consideradas conjuntamente, as classes alta e muito alta passam de aproximadamente 19% no presente para cerca de 49% no SSP1-2.6 e 46% no SSP5-8.5. As projeções não indicam apenas aumento da probabilidade média, mas uma reorganização expressiva das classes de propensão, com redução das áreas de baixa propensão e expansão das categorias superiores.

Tabela 4. Área (10^3 km²) e participação percentual (entre parênteses) de cada classe de propensão ao fogo no presente e nos cenários de 2021–2040 (média dos modelos climáticos).

Classe de propensão	Presente	SSP1-2.6	SSP5-8.5
Baixa (0–0,25)	563,6 (61,5%)	278,7 (30,4%)	314,3 (34,3%)
Moderada (0,25–0,50)	178,2 (19,4%)	190,6 (20,8%)	182,6 (19,9%)
Alta (0,50–0,75)	94,2 (10,3%)	200,2 (21,8%)	195,3 (21,3%)
Muito alta (0,75–1,00)	80,2 (8,7%)	246,8 (26,9%)	224,0 (24,5%)
Total	916,2	916,3	916,2

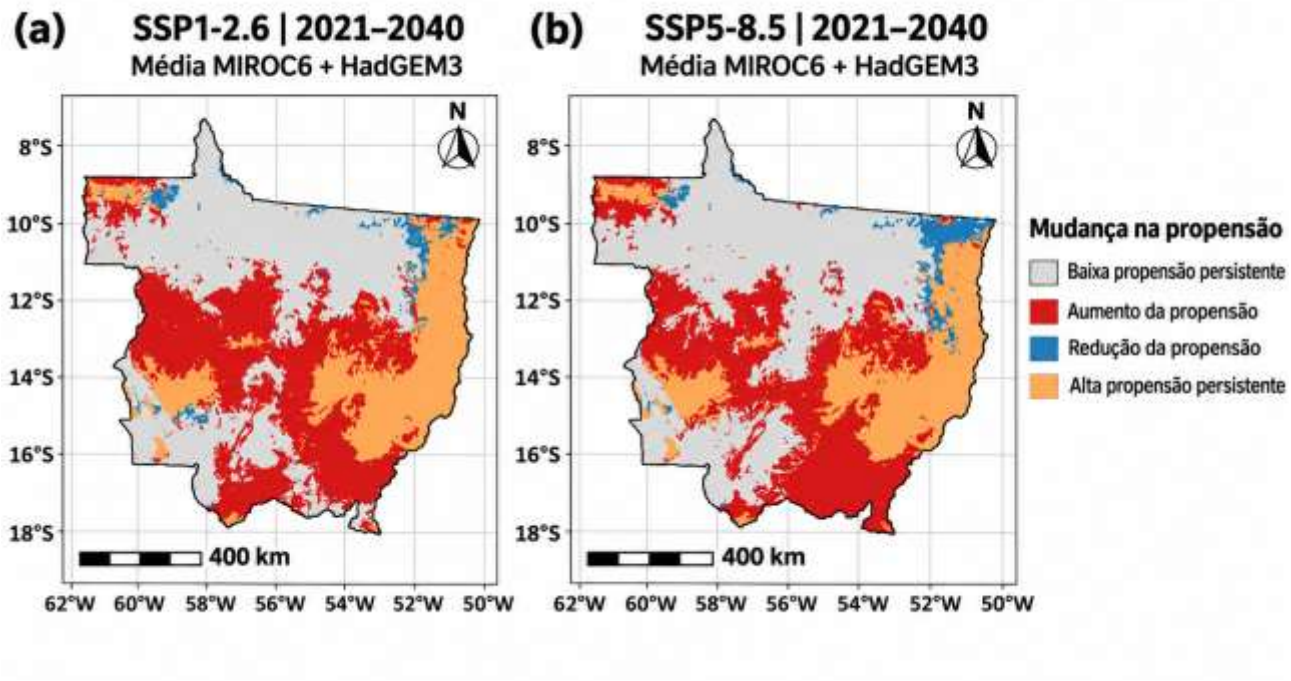
Fonte: Elaborada pelos autores (2026). Áreas lidas nos rótulos do gráfico original; percentuais não citados no texto original foram calculados pela razão entre a área da classe e o total.

A análise das áreas de ganho, perda e persistência reforça esse padrão. Considerando a média dos modelos climáticos, aproximadamente 33,5% da área apresenta aumento da propensão no SSP1-2.6, enquanto apenas 2,1% apresenta redução. Para o SSP5-8.5, os valores correspondem a aproximadamente 31,5% de aumento e 3,1% de redução. Dessa forma, as mudanças projetadas são predominantemente direcionadas ao aumento da propensão. Paralelamente, cerca de 20–21% da área permanece na condição de alta propensão entre o presente e as projeções futuras, configurando um núcleo de persistência espacial. Essas áreas merecem especial atenção do ponto de vista do planejamento, pois apresentam elevada propensão tanto nas condições atuais quanto nas projeções analisadas.

A distribuição espacial dessas classes (Figura 10) evidencia que a alta propensão persistente corresponde essencialmente aos núcleos já identificados no presente: o corredor do leste, ao longo do Vale do Araguaia, o bloco central-sul do Cerrado e a Chapada dos Parecis. As áreas de aumento da propensão formam um cinturão que circunda esses núcleos e se expande sobre a faixa de transição Amazônia–Cerrado, o enclave amazônico do centro-oeste, o sudoeste do estado e o planalto ao sul, em direção à borda do Pantanal. No SSP5-8.5, esse avanço é mais pronunciado no extremo sul, que passa quase integralmente à classe de aumento, enquanto no SSP1-2.6 o aumento é mais extenso no centro-

norte da faixa de transição. A baixa propensão persistente predomina no núcleo amazônico do norte e na planície pantaneira.

Figura 10. Mudança na propensão ao fogo entre o presente e 2021–2040, média dos modelos MIROC6 e HadGEM3-GC31-LL: (a) SSP1-2.6; (b) SSP5-8.5.



Fonte: Elaborado pelos autores, 2026

As áreas de redução, embora pouco extensas, apresentam padrão espacial bem definido. Elas se concentram no nordeste do estado, na transição Amazônia–Cerrado entre 51° W e 52,5° W e entre 10° S e 12,5° S, e no noroeste, em torno de 9,3° S e 59° W, setores que no presente estavam entre os de maior propensão. A redução é mais extensa no SSP5-8.5, cenário de maior aquecimento, o que é compatível com o declínio da curva de bio5 acima de aproximadamente 35,5 °C e com a queda local da curva de bio4. Nessas áreas, portanto, o aquecimento projetado parece deslocar as condições para além do ótimo estimado pelo modelo. Como esse comportamento ocorre no extremo do gradiente amostrado, onde há menos registros de presença, é possível que se trate de um efeito de extrapolação, e não de uma redução real do risco, o que reforça a necessidade de avaliar essas áreas por meio da análise MESS (Elith; Kearney; Phillips, 2010).

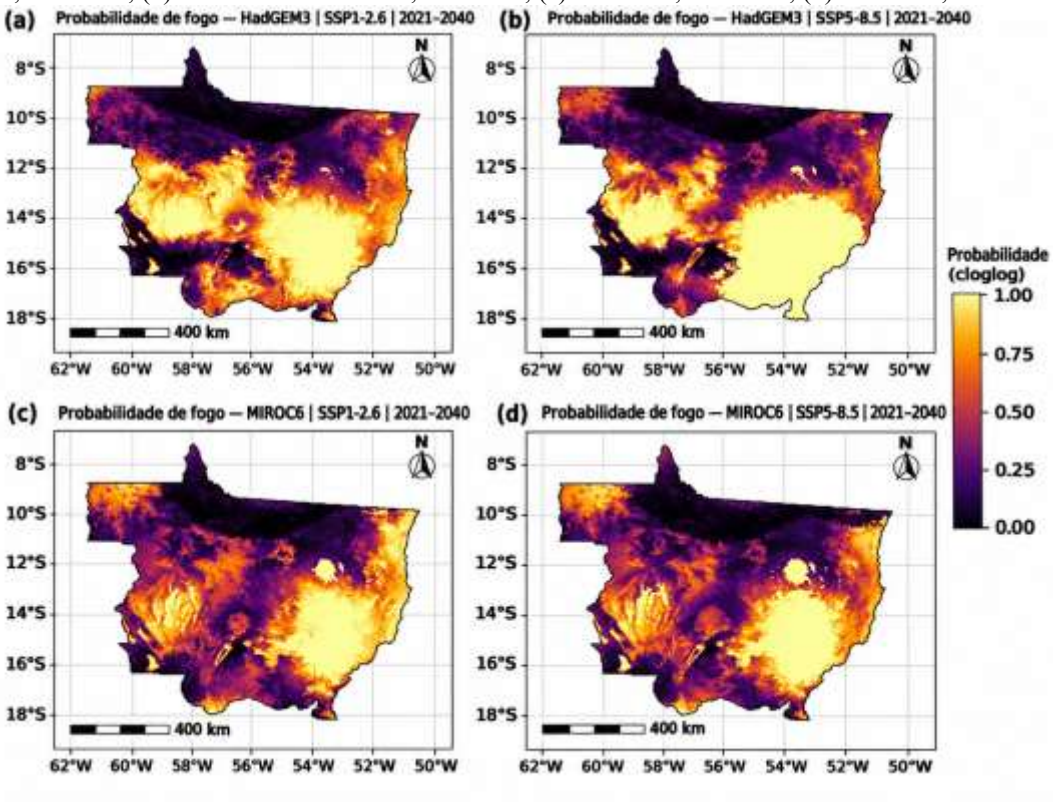
4.5 INCERTEZA ENTRE MODELOS CLIMÁTICOS

As diferenças entre os modelos climáticos constituem, contudo, uma fonte relevante de incerteza. Para o SSP1-2.6, por exemplo, a probabilidade média varia de aproximadamente 0,466 no

MIROC6 para 0,518 no HadGEM3. No SSP5-8.5, varia de cerca de 0,445 para 0,504, respectivamente (Tabela 3). As estimativas espaciais de aumento da propensão variam consideravelmente entre os modelos climáticos. Isso demonstra que, para o horizonte 2021–2040, a incerteza associada ao modelo climático utilizado pode ser tão ou mais importante que a diferença entre os cenários de emissão considerados.

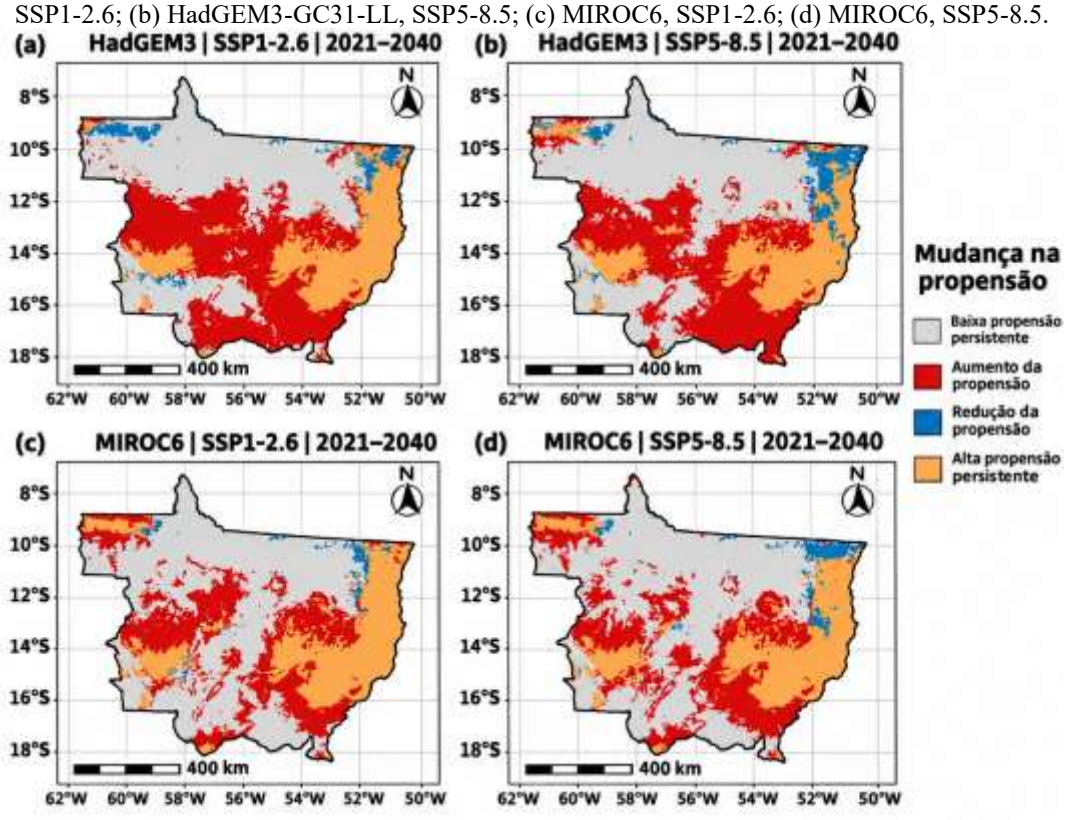
A comparação entre os modelos climáticos individuais (Figuras 11 e 12) permite identificar onde essas divergências se manifestam. O HadGEM3-GC31-LL projeta um núcleo saturado, com probabilidade próxima de 1,0, muito mais extenso no centro-sul, que no SSP5-8.5 abrange praticamente todo o setor entre 52° W e 56° W ao sul de 13,5° S, incluindo o extremo sul do estado. Esse modelo também projeta forte avanço da propensão sobre o centro-oeste e a faixa de transição, e redução no noroeste amazônico e no nordeste do estado. O MIROC6, por sua vez, projeta aumentos menos extensos e mais fragmentados, concentrados no leste e no centro-sul, mantém probabilidades elevadas no noroeste e restringe o avanço sobre o extremo sul. Desse modo, enquanto o HadGEM3 desloca a propensão para o sul e para o centro-oeste, o MIROC6 mantém uma configuração mais próxima da atual, ampliando principalmente os núcleos já existentes. Destaca-se ainda, no MIROC6, um núcleo isolado de propensão máxima em torno de 12° S e 53,5° W, já perceptível no presente, e bem menos extenso no HadGEM3.

Figura 11. Probabilidade de ocorrência de fogo projetada para 2021–2040 por modelo climático: (a) HadGEM3-GC31-LL, SSP1-2.6; (b) HadGEM3-GC31-LL, SSP5-8.5; (c) MIROC6, SSP1-2.6; (d) MIROC6, SSP5-8.5.



Fonte: Elaborado pelos autores, 2026

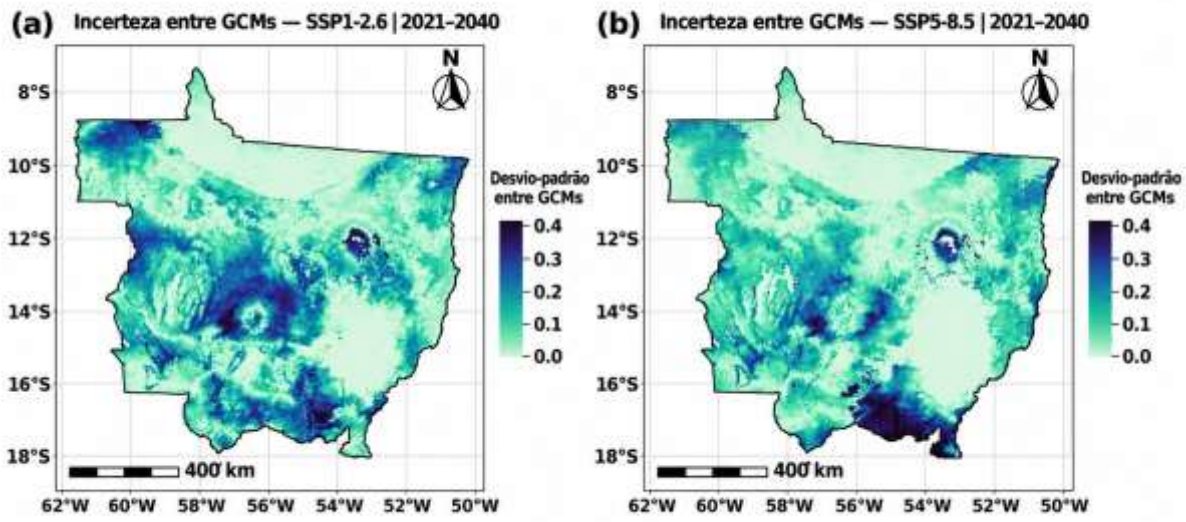
Figura 12. Mudança na propensão ao fogo entre o presente e 2021–2040 por modelo climático: (a) HadGEM3-GC31-LL, SSP1-2.6; (b) HadGEM3-GC31-LL, SSP5-8.5; (c) MIROC6, SSP1-2.6; (d) MIROC6, SSP5-8.5.



Fonte: Elaborado pelos autores, 2026

O desvio-padrão entre os modelos climáticos (Figura 13) sintetiza essas diferenças. Os menores valores ocorrem em duas situações opostas: no núcleo amazônico do norte, onde ambos os modelos projetam baixa propensão, e no núcleo do Cerrado do centro-sul, onde ambos projetam propensão máxima. As maiores incertezas, com desvios superiores a 0,3, concentram-se nas zonas de transição: no centro-oeste, entre 55° W e 58° W e entre 13° S e 15° S, na transição Amazônia–Cerrado e no entorno do enclave amazônico; na borda oeste, próximo a 60° W; no núcleo isolado em torno de 12° S e 53,5° W; e no sul do estado. No SSP5-8.5, a incerteza máxima, com desvios próximos ou superiores a 0,4, desloca-se para o extremo sul, entre 54° W e 56° W e ao sul de 16° S, no planalto adjacente ao Pantanal, justamente onde o HadGEM3 projeta saturação e o MIROC6 não.

Figura 13. Incerteza entre os modelos climáticos, expressa pelo desvio-padrão da probabilidade de ocorrência de fogo entre MIROC6 e HadGEM3-GC31-LL para 2021–2040: (a) SSP1-2.6; (b) SSP5-8.5.



Fonte: Elaborado pelos autores, 2026

Esse padrão é consistente com o mecanismo de limiar discutido anteriormente. Nas áreas em que as condições atuais se aproximam dos pontos de inflexão das curvas de resposta, pequenas diferenças entre as temperaturas projetadas pelos modelos climáticos resultam em grandes diferenças de probabilidade. Em termos práticos, as zonas de transição entre biomas, que concentram as maiores mudanças projetadas, são também as que apresentam maior incerteza. Isso recomenda cautela na sua delimitação como áreas prioritárias e reforça a importância de ampliar o número de modelos climáticos em estudos futuros. A convergência entre os modelos quanto à alta propensão no Cerrado do centro-

sul e do leste, e quanto à baixa propensão climática no núcleo amazônico, confere maior robustez a esses resultados.

4.6 LIMITAÇÕES

Algumas limitações precisam ser consideradas na interpretação dos resultados. Os resultados da análise MESS prevista na metodologia não são apresentados neste manuscrito, o que impossibilita avaliar diretamente em quais áreas as projeções futuras extrapolam as condições utilizadas durante a calibração. Esse aspecto é especialmente importante porque as variáveis térmicas figuram entre os principais preditores do modelo. Além disso, foram utilizados apenas dois modelos climáticos, o que restringe a representação da incerteza intermodelos. A exclusão da proporção de área não vegetada também significa que as projeções futuras mantêm os componentes de uso da terra fora da dinâmica temporal considerada. Assim, os mapas futuros representam fundamentalmente a resposta do modelo às alterações das condições climáticas, condicionadas pelo relevo, e não uma previsão integrada das mudanças climáticas e das transformações futuras do uso e cobertura da terra.

Outras limitações são o período de registros de fogo não informado, que impede verificar sua coerência com a linha de base climática do WorldClim; a divisão aleatória dos dados em treinamento, validação e teste, sem controle da autocorrelação espacial; a ausência de fatores de ignição humana; e a ausência de validação independente das projeções, que são resultados de modelo e não observações. Também deve ser considerada uma pequena discrepância na área total utilizada nos cálculos: a soma das classes resulta em aproximadamente 916 mil km², valor ligeiramente superior à área de aproximadamente 900 mil km² mencionada para o estado (Tabela 4). Essa diferença pode estar relacionada à representação *raster* e aos pixels situados nos limites da área de estudo, mas essa hipótese precisa ser confirmada a partir do procedimento de processamento espacial empregado, e as áreas devem ser lidas como áreas de células, e não como áreas territoriais oficiais.

Em síntese, a modelagem evidencia que foi possível obter um modelo relativamente parcimonioso, com pequena diferença de desempenho entre treinamento e teste e predominância de variáveis climáticas na explicação da propensão ao fogo. A sazonalidade da temperatura, a temperatura máxima do mês mais quente e a amplitude térmica anual apresentaram papel destacado, acompanhadas pela precipitação do mês mais seco e pela elevação. Para 2021–2040, as projeções convergem para uma expansão das áreas de maior propensão, embora a magnitude dessa expansão varie entre os modelos climáticos.

5 CONCLUSÃO

A modelagem espacial permitiu identificar padrões atuais e potenciais mudanças futuras na propensão à ocorrência de fogo no estado de Mato Grosso, evidenciando a influência predominante das condições climáticas, especialmente das variáveis relacionadas à sazonalidade e aos extremos de temperatura. O modelo MaxEnt apresentou desempenho preditivo satisfatório e estabilidade entre os conjuntos de treinamento e teste, com AUC de 0,837 e 0,830, respectivamente, indicando capacidade adequada de discriminação espacial das áreas mais propensas ao fogo.

Nas condições presentes, as áreas de maior propensão concentram-se principalmente no Cerrado, no leste e centro-sul do estado, além de núcleos localizados na Chapada dos Parecis e em zonas de transição entre Amazônia e Cerrado. As projeções para 2021–2040 indicam uma expansão expressiva das áreas de maior propensão em ambos os cenários climáticos avaliados. As classes alta e muito alta, que atualmente representam aproximadamente 19% da área analisada, podem alcançar cerca de 49% no SSP1-2.6 e 46% no SSP5-8.5. Além disso, aproximadamente 33,5% e 31,5% do território apresentam aumento da propensão nos cenários SSP1-2.6 e SSP5-8.5, respectivamente.

As zonas de transição entre os biomas destacaram-se tanto pela magnitude das mudanças projetadas quanto pelas maiores divergências entre os modelos climáticos, demonstrando que a incerteza intermodelos constitui um aspecto relevante para a interpretação das projeções. Em contrapartida, a convergência dos modelos quanto à manutenção de elevada propensão em áreas do Cerrado do centro-sul e leste confere maior robustez à identificação desses setores como áreas de atenção para estratégias de prevenção e planejamento. Essas conclusões referem-se à propensão climática e topográfica ao fogo, com uso da terra constante, e não à probabilidade de ignição nem à área que de fato queimará.

Estudos futuros poderão integrar cenários dinâmicos de uso da terra, maior conjunto de modelos climáticos e análises de extrapolação ambiental, ampliando a robustez das estimativas. Ainda assim, os padrões identificados fornecem subsídios relevantes para reconhecer áreas potencialmente mais suscetíveis ao fogo e apoiar estratégias de prevenção, monitoramento e gestão territorial em Mato Grosso.

AGRADECIMENTOS

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. 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.

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.

BIUDES, Marcelo Sacardi; GELI, Hatim M. E.; VOURLITIS, George Louis *et al.* Evapotranspiration seasonality over tropical ecosystems in Mato Grosso, Brazil. Remote Sensing, v. 14, n. 10, 2482, 2022. DOI: https://doi.org/10.3390/rs14102482.

CHOU, Yue Hong; MINNICH, Richard A.; CHASE, Richard A. Mapping probability of fire occurrence in San Jacinto Mountains, California, USA. Environmental Management, v. 17, n. 1, p. 129-140, 1993. DOI: https://doi.org/10.1007/bf02393801.

D'ACUNHA, B.; DALMAGRO, H. J.; ZANELLA DE ARRUDA, P. H. *et al.* Changes in evapotranspiration, transpiration and evaporation across natural and managed landscapes in the Amazon, Cerrado and Pantanal biomes. Agricultural and Forest Meteorology, v. 346, 109875, 2024. DOI: https://doi.org/10.1016/j.agrformet.2023.109875.

ELITH, Jane; KEARNEY, Michael; PHILLIPS, Steven. The art of modelling range-shifting species. Methods in Ecology and Evolution, v. 1, n. 4, p. 330-342, 2010. DOI: https://doi.org/10.1111/j.2041-210x.2010.00036.x.

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.

EYRING, Veronika; BONY, Sandrine; MEEHL, Gerald A. *et al.* Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. Geoscientific Model Development, v. 9, n. 5, p. 1937-1958, 2016. DOI: https://doi.org/10.5194/gmd-9-1937-2016.

FAIRBROTHER, Anne; TURNLEY, Jessica G. Predicting risks of uncharacteristic wildfires: application of the risk assessment process. Forest Ecology and Management, v. 211, n. 1-2, p. 28-35, 2005. DOI: https://doi.org/10.1016/j.foreco.2005.01.026.

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.

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.

IBGE – Instituto Brasileiro de Geografia e Estatística. Biomas e Sistema Costeiro-Marinho. Rio de Janeiro: IBGE, 2025.

LI, Sihan; SPARROW, Sarah N.; OTTO, Friederike E. L. *et al.* Anthropogenic climate change contribution to wildfire-prone weather conditions in the Cerrado and Arc of deforestation. Environmental Research Letters, v. 16, n. 9, 094051, 2021. DOI: https://doi.org/10.1088/1748-9326/ac1e3a.

LIBONATI, Renata; GEIRINHAS, João L.; SILVA, Patrícia S. *et al.* Assessing the role of compound drought and heatwave events on unprecedented 2020 wildfires in the Pantanal. Environmental Research Letters, v. 17, n. 1, 015005, 2022. DOI: https://doi.org/10.1088/1748-9326/ac462e.

MAEDA, Eduardo Eiji; FORMAGGIO, Antonio Roberto; SHIMABUKURO, Yosio Edemir *et al.* Predicting forest fire in the Brazilian Amazon using MODIS imagery and artificial neural networks. International Journal of Applied Earth Observation and Geoinformation, v. 11, n. 4, p. 265-272, 2009. DOI: https://doi.org/10.1016/j.jag.2009.03.003.

MAPBIOMAS. Coleção 11 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil. [S. l.]: MapBiomas, 2026. Disponível em: https://brasil.mapbiomas.org. Acesso em: 6 out. 2026.

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.

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.

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.

PHILLIPS, Steven J.; ANDERSON, Robert P.; DUDÍK, Miroslav *et al.* Opening the black box: an open-source release of Maxent. Ecography, v. 40, n. 7, p. 887-893, 2017. DOI: https://doi.org/10.1111/ecog.03049.

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.

RODRIGUES, C. A. G.; CRISPIM, S. M. A.; COMASTRI FILHO, J. A. Queima controlada no Pantanal. Corumbá: Embrapa Pantanal, 2002. 23 p.

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, Juliana Ferreira; SOARES, Ronaldo Viana; BATISTA, Antonio Carlos. Perfil dos incêndios florestais no Brasil em áreas protegidas no período de 1998 a 2002. Floresta, v. 36, n. 1, 2006. DOI: https://doi.org/10.5380/rf.v36i1.5510.

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.

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.

VERSIEUX, Verônica; COSTA, Marcos Heil. Local evapotranspiration is the only relevant source of moisture at the onset of the rainy season in South America. Atmosphere, v. 15, n. 8, 932, 2024. DOI: https://doi.org/10.3390/atmos15080932.

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.

WHITE, Larissa Alves Secundo; WHITE, Benjamin Leonardo Alves; RIBEIRO, Genésio Tâmara. Modelagem espacial de risco de incêndio florestal para o município de Inhambupe, Bahia, Brasil. Pesquisa Florestal Brasileira, v. 36, n. 85, 41, 2016. DOI: https://doi.org/10.4336/2016.pfb.36.85.850.