

Estado da publicação: O preprint não foi publicado em outro meio.

Predição e tipificação do uso do fogo na região da Amazônia Legal no Brasil: Estudo com base nos eventos detectados pelo Painel do Fogo

Jack Endrick Pastrana Mojica, Tássia Fraga Belloli, Pamela Boelter Herrmann, Deyvis Cano, Camila Souza Silva

<https://doi.org/10.1590/SciELOPreprints.14897>

Submetido em: 2026-01-19

Postado em: 2026-01-20 (versão 1)

(AAAA-MM-DD)

Predição e Tipificação do Uso do Fogo na Região da Amazônia Legal no Brasil: Estudo com Base nos Eventos Detectados pelo Painel do Fogo

Prediction and Typification of Fire Use in the Legal Amazon Region of Brazil: A Study Based on Events Detected by the Fire Panel

Jack Endrick Pastrana Mojica¹

jack.pastrana@ufrgs.br

ORCID: <https://orcid.org/0009-0003-9539-1381>

Tássia Fraga Belloli¹

tassia.belloli@ufrgs.br

ORCID: <https://orcid.org/0000-0001-6365-7796>

Pamela Boelter Herrmann¹

pamela.herrmann@ufrgs.br

ORCID: <https://orcid.org/0000-0001-9049-3141>

Deyvis Cano¹

deyvis.cano@ufrgs.br

ORCID: <https://orcid.org/0000-0002-4262-1505>

Camila Souza Silva²

camila.souza.tercerizada@ibama.gov.br

ORCID: <https://orcid.org/0000-0002-6271-2973>

¹ Universidade Federal do Rio Grande do Sul (UFRGS), Brasil - ² Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA), Brasil.

Resumo: Esta pesquisa tem como objetivo entender os diferentes usos do fogo na gestão, por meio das queimadas prescrita, controlada e de combate, cruzadas com os dados do Painel de Fogo do CENSIPAM no ano de 2023. Foram aplicadas técnicas de aprendizado de máquina para realizar previsões. Foi possível gerar insights sobre os impactos do uso do fogo nas Unidades Federativas (UFs). O modelo Random Forest apresentou a maior acurácia global (76%). As queimadas de combate e prescrita tiveram maior precisão (0,90% e 0,69%, respectivamente). As curvas ROC e os valores AUC indicaram boa capacidade de distinção entre essas classes (0,84 e 0,79), enquanto a queimada controlada apresentou menor capacidade de generalização. Os valores de Shapley Additive Explanations (SHAP) destacaram as variáveis biomassa e áreas sem fiscalização como fatores que contribuem para a modelagem da tipificação de ocorrências de queimadas.

Palavras-chave: Aprendizado de máquina; Tipificação de fogo; Amazônia Legal; Painel do Fogo.

Abstract: This research aims to understand the different uses of fire in management, through prescribed, controlled, and combat fires, cross-referenced with data from the CENSIPAM Fire Panel in 2023. Machine learning techniques were applied to make predictions. It was possible to generate insights into the impacts of fire use in the Federal Units (UFs). The Random Forest model showed the highest overall accuracy (76%). Combat and prescribed fires had the highest precision (0.90% and 0.69%, respectively). The ROC curves and AUC values indicated good discrimination capacity between these classes (0.84 and 0.79), while controlled burning showed lower generalization ability. Shapley Additive Explanations (SHAP) values highlighted biomass and areas without oversight as factors contributing to the modeling of fire occurrence classification.

Keywords: Machine learning; Fire classification; Legal Amazon; Fire Panel.

Introdução

Nas últimas décadas, a Amazônia Legal tem enfrentado intensificação de incêndios florestais, impulsionados por desmatamento ilegal, expansão agropecuária e mudanças climáticas. Rocha e Rauber (2023) demonstram que 85% dos focos de calor entre 2001 e 2020 estão correlacionados com desmatamento de corte raso, especialmente em áreas de fronteira agrícola. Eventos como o "Dia do Fogo" em 2019, que resultou em aumento de 29,67% nas queimadas, evidenciam a sinergia entre ações criminosas, grilagem e fragilidade institucional (CNJ, 2024; IPAM, 2024). Esses incêndios liberam gases de efeito estufa, degradam habitats e comprometem serviços ecossistêmicos, como regulação hídrica e polinização, impactando diretamente a saúde de populações locais (REDDINGTON *et al.*, 2015; ALENCAR *et al.*, 2020).

Nesse contexto a regulamentação do uso do fogo na Amazonia Legal ainda está em desenvolvimento (DE ANDRADE *et al.*, 2021). Embora o Código Florestal de 1965 (Lei nº 4.771) tenha sido a primeira norma a abordar o tema, a legislação ao longo das décadas manteve um caráter restritivo. Normas posteriores, como o Decreto nº 84.017/1979, a Resolução CONAMA nº 11/1988 e o Decreto nº 2.661/1998, reconheceram o papel do fogo em determinados contextos, mas com ênfase na sua proibição. Apenas com a Lei nº 12.651/2012, que instituiu o novo Código Florestal, o uso do fogo passou a ter respaldo legal para fins ecológicos e culturais, fortalecendo a implementação do Manejo Integrado do Fogo (MIF).

Considerando tal cenário, o MIF, é uma prática de grande relevância para a conservação ambiental e as atividades agrossilvipastoris no Brasil, exigindo regulamentação para garantir seu uso sustentável. Assim, a Lei 14.944/2024 (BRASIL, 2024) estabelece definições essenciais para diferenciar incêndios florestais, que são eventos não controlados e não planejados, da queima controlada, utilizada para fins produtivos sob condições específicas, e da queima prescrita, aplicada para conservação ambiental. Compreender essas definições é fundamental para a formulação de políticas eficazes de gestão do fogo.

Nesse sentido, é importante destacar o esforço do Centro Especializado de Manejo Integrado do Fogo (CEMIF/ICMBio), que pode ser considerada como a primeira iniciativa a contribuir em diferentes momentos do MIF. Isso ocorre porque define de forma detalhada a tipificação do fogo, abrangendo os aspectos agropecuários, culturais, de conservação e ecológicos no país amparado pela Portaria ICMBio nº 1.150 (BRASIL, 2022) que estabelece princípios, diretrizes, finalidades, instrumentos e procedimentos para a implementação do MIF nas UCs.

Dessa forma, parte-se da premissa de que aprender a diferenciar os diferentes tipos de incêndios (BARLOW *et al.*, 2020) é essencial para direcionar respostas eficazes por parte das entidades de controle e monitoramento do fogo no Brasil, permitindo que atuem de maneira eficiente e adequada. Assim, esta pesquisa contribui de forma significativa para o debate sobre os fatores que influenciam a gestão do fogo, além de fornecer instrumentos e conceitos para a política prevista no MIF. Isto porque a compreensão dos principais fatores associados à dinâmica do fogo (HERRMANN *et al.*, 2023) permite analisar como as diferentes práticas na gestão do fogo vêm sendo desenvolvidas na Amazônia Legal.

Tendo em vista que essa problemática envolve lacunas de conhecimento, esta pesquisa tem como objetivo modelar o comportamento do fogo com base em atributos intrínsecos dos indicadores fornecidos pela plataforma Painel de Fogo, utilizando técnicas de aprendizado de máquina (AKINCI e ZEYBEK *et al.*, 2021; PANG *et al.*, 2022). Essa abordagem se justifica pela necessidade de um planejamento eficiente nos três âmbitos da gestão do fogo: a preservação do uso tradicional pelas comunidades, a compreensão dos atributos ecológicos e a implementação de atividades de proteção.

Se espera que os eventos de fogo monitorados pelo Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM), por meio da plataforma Painel do Fogo, quando cruzados com

dados de ocorrências de incêndios, ofereçam insights valiosos sobre os padrões de queimadas e incêndios florestais na Amazônia (FERRO *et al.*, 2023), mesmo reconhecendo o grande desafio que essa tarefa implica.

Área de Estudo

A Amazônia Legal, instituída pela Lei nº 1.806/1953, abrange nove estados brasileiros: Acre, Amapá, Amazonas, Pará, Rondônia, Roraima, Tocantins, além de porções do Mato Grosso e Maranhão (Figura 1). Com cerca de 59% do território nacional (SOUZA *et al.*, 2024), a região engloba biomas críticos, como a Floresta Amazônica e o Cerrado, além de áreas de transição ecológica. Sua importância transcende fronteiras: atua como reguladora do clima global, armazena aproximadamente 20% da água doce do planeta e abriga 20% da biodiversidade mundial (XU *et al.*, 2021). Além disso, sustenta comunidades tradicionais e indígenas, cujas práticas de manejo comunitário são essenciais para a conservação, embora enfrentem desafios como a falta de apoio institucional (SOARES *et al.*, 2022). A região também desempenha papel central na mitigação das mudanças climáticas, funcionando como sumidouro de carbono e preservando saberes ancestrais ligados à floresta (ARAGÃO *et al.*, 2008). Apesar de políticas como o Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm) terem reduzido o desmatamento entre 2004 e 2012, a flexibilização de leis ambientais e a atuação de redes criminosas, envolvendo lavagem de recursos e corrupção, reacenderam a pressão sobre a floresta (HOMMA, 2020).

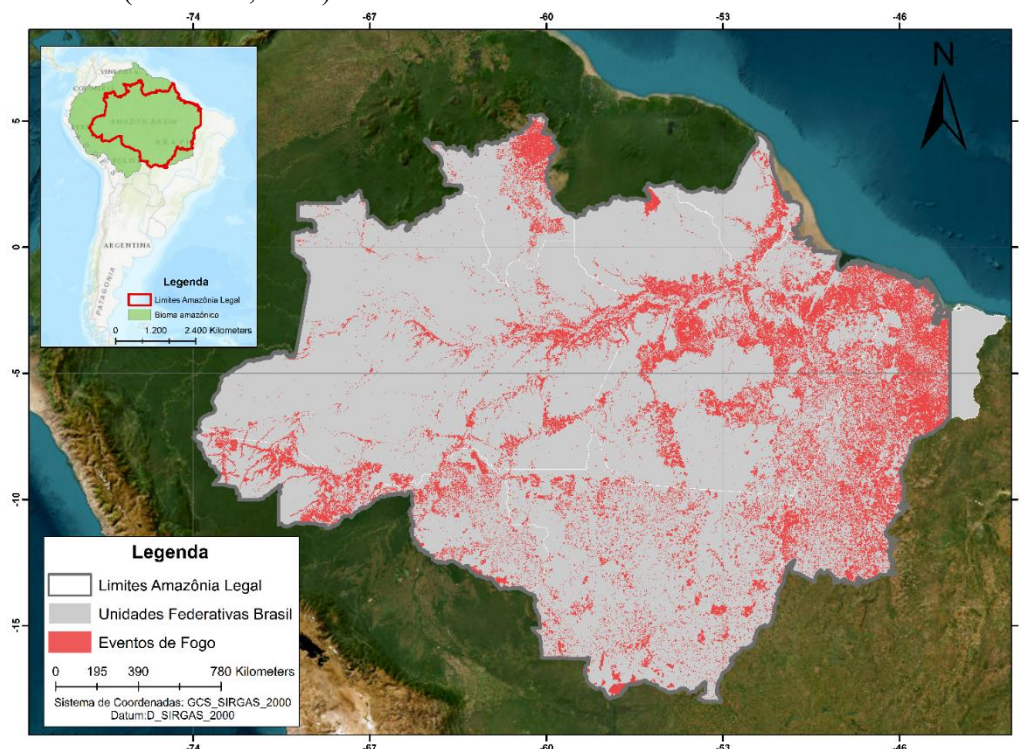


Figura 1 – Eventos de fogo do Painel de fogo do CENSIPAM utilizados no cruzamento com as ocorrências de fogo do ICMBio no ano 2023 na Amazonia Legal.

Metodologia

Coleta e classificação relatórios de ocorrências de incêndios ICMBIO

Foi coletada o reporte de ocorrências do fogo do ICMBio do ano 2023, que aprestaram estritamente quatro parâmetros necessários para sua espacialização: coordenadas, data, tipo de queima e Unidade Federal, ou nome do parque de conservação onde foi atendida a ocorrência (Tabela 1). Vale

ressaltar que neste trabalho, dados dos relatórios do ICMBio e CBM que não tiveram coordenadas, foram excluídos do processo de mapeamento da informação.

Tabela 1 – Estilo de formatação os relatórios de ocorrências de fogo apresentados por ICMBio.

Data	Nome_UCs	Observações	Coordenadas
08/08/2023	Parque Nacional das Sempre-Vivas	Focos captados na tarde do dia 08/08 no limite sudeste da unidade. A gestão monitora e destaca que os focos são em área de pastagem, caso persistam amanhã, a brigada se deslocará para combate.	Lat -17.96767 Lon -43.73145
20/08/2023	Reserva Biológica Nascentes da Serra do Cachimbo	Incêndio na porção nordeste da unidade. Nove brigadistas da UNA Itaituba estão em combate com apoio de 5 servidores da Força Nacional desde o dia 16/08.	Lat -8.72735 Lon -54.5

Acervo Base de dados de eventos do fogo (Painel do fogo)

Os eventos de fogo utilizados para o cruzamento com as ocorrências do ICMBio foram fornecidos pelo Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM), em parceria com o Laboratório de Imagens, Sinais e Acústica (LISA) da Universidade de Brasília (UNB). Foram definidos parâmetros específicos a serem incluídos no conjunto de dados para melhorar a eficiência dos modelos de aprendizado de máquina para a tipificação de fogo (Tabela 2).

Tabela 2 – Características da base de dados dos eventos de fogo ano 2023 utilizados na pesquisa.

Atributo	Descrição
area_km ²	Área do evento de fogo
areakm ² _uc	Área de Unidade de Conservação dentro do evento de fogo
persistenc	Duração do evento de fogo em dias.
qtd_detecc	Número de focos de calos dentro dos eventos de fogo (km ²)
a_terr_pri	Área de terras privadas dentro do evento de fogo (km ²)
a_terr_pub	Área de terras públicas dentro do evento de fogo (km ²)
a_terr_in	Área de terras indígenas dentro do evento de fogo(km ²)
area_car	Área de cadastro rural dentro do evento de fogo (km ²)
a_terr_unk	Área de que não são categorizadas como privadas nem públicas que se encontram dentro do evento de fogo (km ²)
biomass_gs	Biomassa estocada no solo na área do evento (t/ha)
biomass_ag	Biomassa área na área do evento (t/ha)
tree_cover	Cobertura de arvores (Km ²)
deter_area	Área desmatada (km ²) projeto DETER

*A base de dados de incêndios utilizada corresponde aos produtos do *GFED Amazon Dashboard*, ao SICAR (Sistema de Cadastro Ambiental Rural, 2023), além das características intrínsecas dos atributos da camada “*tb eventos*” do Painel de Fogo do ano de 2023.

Cruzamento de ocorrências do fogo e eventos do fogo do painel

Uma vez espacializada as ocorrências de fogo previamente verificados do ICMBio, se procedeu à criação de um banco de dados local em *Postgresql* (POSTGRESQL DEVELOPERS, 2024) que

permitiu a integração e cruzamento com as informações dados do Painel do Fogo. Para isso foi empregada a metodologia utilizada por Mojica *et al.*, (2024), dessa forma, as ocorrências de fogo contidas dentro do evento detectado ($Dentro_evento = true$) e que apresentaram a mesma data reportada, tanto nos relatórios do ICMBio quanto nos eventos de fogo ($data\ ocorrência \geq dt_evento\ AND\ data\ ocorrência \leq dt_evento$), foram consideradas na análise. Finalmente, para garantir que os eventos cruzados correspondessem às áreas de monitoramento do Painel do Fogo, foi utilizada a camada de escopos de áreas espúrias (ANTUNES *et al.*, 2023). Assim, assegurou-se que os eventos intersectados com as ocorrências estivessem localizados nas áreas de monitoramento rural operadas pelo Painel do Fogo.

Implementação e validação dos modelos de aprendizado de máquina

Após o cruzamento dos dados, foi necessário padronizar o conjunto de dados com intuito de tornar as observações comparáveis e obter melhores desempenho nos resultados. O método mais comum é o Min-Max, que consiste em:

$$IA_{\text{padronizadoj}} = \frac{IA_j - IA_{\text{min}}}{IA_{\text{max}} - IA_{\text{min}}} \quad (1)$$

Sendo IA_j instancia a padronizar, IA_{min} valor mínimo nas instancias (mínimo valor entre as observações) e IA_{max} o valor máximo nas observações.

Uma vez feita a padronização dos dados, a fim de reduzir a redundância de informação ou viés nos modelos de aprendizado de máquina, optou-se por aplicar o método de Componentes Principais (PCA), para aumentar o poder preditivo do modelo (HAIR, 2009; FÁVERO *et al.*, 2017), diminuindo assim características que não contribuíram para a predição, além de ter sido verificado a existência de outliers ou valores nulos que pudessem afetar o desempenho da generalização dos modelos.

Seleção de modelos de aprendizado de máquinas

Nesta pesquisa, foram utilizados os modelos Arvores de Decisão (*Decision Tree - DT*), Floresta aleatória (*Random Forest - RF*) e Máquina Vector de Suporte (*Support Vector Machine - SVM*) (BREIMAN, 2001; KAVZOGLU *et al.*, 2009; ALKAN *et al.*, 2024).

Para avaliar a capacidade de generalização dos modelos, utilizamos o método *Holdout (Random Resampling)*, variando a composição de diferentes subconjuntos de treinamento e teste (MAILLARD *et al.*, 2021), onde foram realizadas k vezes repetições dentro dos conjuntos de treinamento e validação, mas mantendo os mesmos parâmetros do algoritmo de aprendizagem. Adicionalmente foi utilizada a técnica *cross-validation* (Pérez *et al.*, 2015) que consiste em dividir o conjunto de dados em k -fold, garantindo que pelo menos uma vez cada uma das instâncias possa ser utilizada no treinamento, ou que ajuda a prevenir que modelo tenha sobreajuste e seja capaz de melhorar sua capacidade de generalização no conjunto de teste (Li *et al.*, 2020; ALKAN *et al.*, 2024).

Nesse sentido, o conjunto de dados foi dividido em 70% para treinamento, 15% para validação e 15% para teste. Após as simulações, foram selecionadas as combinações de hiperparâmetros mais otimizadas na etapa de generalização para dados não vistos (tabela 3). A escolha dos modelos e hiperparâmetros foi baseada na biblioteca Scikit-learn (Pedregosa *et al.*, 2011).

Tabela 3 – Seleção de algoritmos e hiperparâmetros.

Algoritmos	Hiperparâmetros
Vector Support Machine	C= 10, kernel= 'rbf', probability = True
Decision Tree	Random State = 42, min_samples_split = 10, max_features = 13, max_depth= 10
Random Forest	Random State = 42, max_depth= 80, n_estimators= 100, min_samples_split= 10, max_features = 10

Para avaliar o desempenho dos classificadores foram utilizadas as métricas de Acurácia Global (*Overall Accuracy*), definida como o número de predições corretas em cada categoria dividido pelo número total de observações (LI *et al.*, 2020; DONG *et al.*, 2022), pontuação F1, precisão e recall, para calcular os Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN), que são elementos na matriz de confusão (LI *et al.*, 2020 ; PANG *et al.*, 2022; ALKAN *et al.*, 2024).

Por sua vez, para avaliar a qualidade na modelagem do fogo, foi utilizada a métrica *Receiver Operating Characteristic* (ROC) e a *Area Under the Curve* (AUC) (ZHANG *et al.*, 2021) que permitiu relacionar a taxa de verdadeiros positivos (TPR) ou *Recall* (proporção de verdadeiros positivos detectados) e a taxa de falsos positivos (FPR), ou seja, a proporção de falsos positivos entre as instâncias negativas em diferentes limiares de decisão. De acordo com a literatura, um valor de AUC entre 0,5 e 0,6 indica desempenho pobre; entre 0,6 e 0,7, é considerado moderado; entre 0,7 e 0,8, bom; entre 0,8 e 0,9, muito bom; e entre 0,9 e 1,0, excelente (CHEN *et al.*, 2018; AKINCI e ZEYBEK, 2021).

Contribuições dos valores SNAP (Shapley Additive Explanations) nos modelos de aprendizado de máquina

Para determinar como cada variável influência nas decisões dos modelos foram utilizados os valores Shape (LUNDBERG e LEE, 2017; HERRMANN *et al.*, 2023) fornecendo percepções de como os atributos contribuem às predições nos ventos de fogo que cruzaram com as ocorrências de fogo. Fornecendo clareza sobre como os atributos do conjunto de dados são aparentemente mais relevantes para a tarefa de predição e como eles podem impactar nas decisões dos modelos na classificação dos tipos de eventos de fogo.

Resultados e discussão

Espacialização ocorrências de fogo ICMBio

No caso do ICMBio, foram registradas 1.320 ocorrências de fogo na Amazônia Legal em 2023, conforme dados fornecidos pelo próprio instituto. No entanto, apenas 1.264 atenderam aos critérios de validação estabelecidos nesta pesquisa. Assim, 56 ocorrências não apresentaram coordenadas, o que dificultou sua espacialização. Pode-se conferir que o ICMBio, no ano de 2023, registrou 1.264 acionamentos de ocorrências de fogo na Amazônia, no caso das queimadas prescritas, foram registradas 263 ocorrências (20,80%), do tipo controlada 224 (17,72%), enquanto que as operações de combate contabilizaram 777 (61,47%). As UCs com mais acionamentos foi o Parque Nacional do Pantanal Mato-Grossense (95), seguida pela Estação Ecológica Serra Geral do Tocantins (80) e pela Reserva Extrativista Tapajós-Arapiuns (75) (Figura 2).

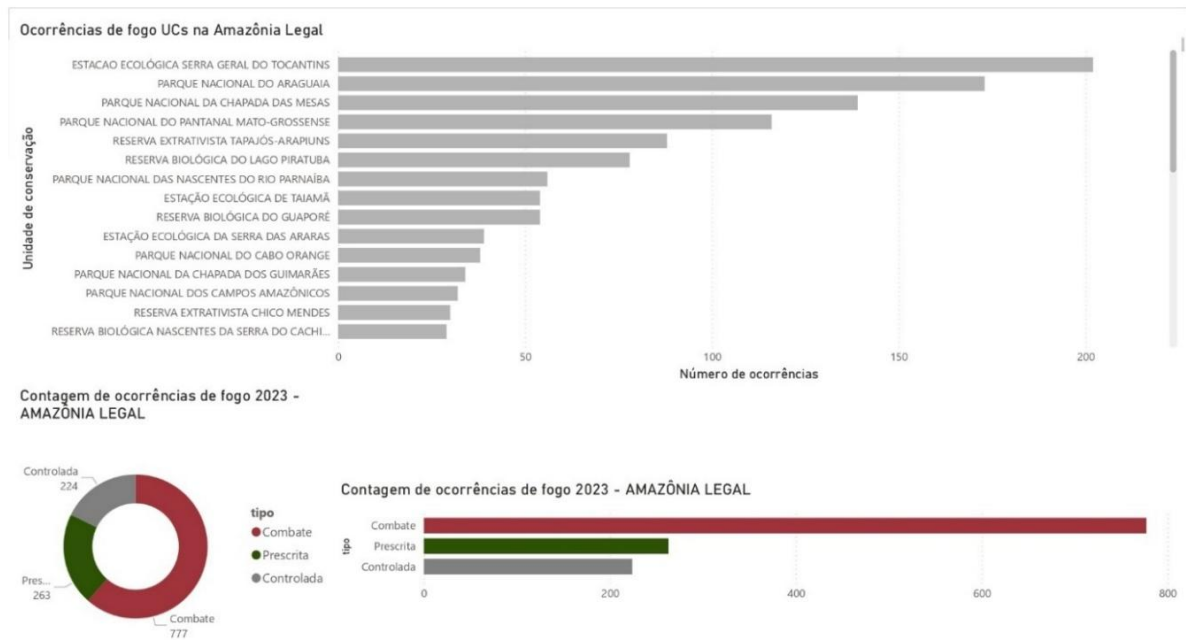


Figura 2 –Verificação e validação de ocorrências de fogo do ICMBio no 2023.

Nesse sentido, observa-se que as UFs do Pará (171), Tocantins (161) e Mato Grosso registraram o maior número de acionamentos para combate (Figura 3). Esse dado pode ser verificado por Mataveli *et al.*, (2024), que afirmam que, somente no Pará, foram registrados 13.804 acionamentos em 2023, em comparação com 4.217 em 2022. Neste caso, autores como Dias *et al.*, (2024) sugerem que esse aumento substancial no uso do fogo pode estar relacionado ao crescimento econômico que esses estados vêm experimentando desde 2020.

Em contraste, Acre, Amazonas e Roraima foram os estados com o menor número de acionamentos para combate ao fogo. Na gestão do uso do fogo, as queimadas prescritas com maior representatividade nas UCs foram: a Estação Ecológica Serra Geral do Tocantins, o Parque Nacional do Pantanal Mato-Grossense e o Parque Nacional da Chapada das Mesas, localizados nos estados de Tocantins (116 ocorrências), Mato Grosso (62 ocorrências) e Maranhão (52 ocorrências), respectivamente. Quanto às queimadas controladas, Tocantins (108) e Maranhão (52) destacam-se pelo número de ocorrências relacionadas ao uso do fogo para desbravar áreas destinadas a pastagens ou cultivos, com a finalidade de facilitar a preparação de novas lavouras e a criação de gado.

Cruzamento das ocorrências de fogo ICMBIO com dados do Painel do Fogo

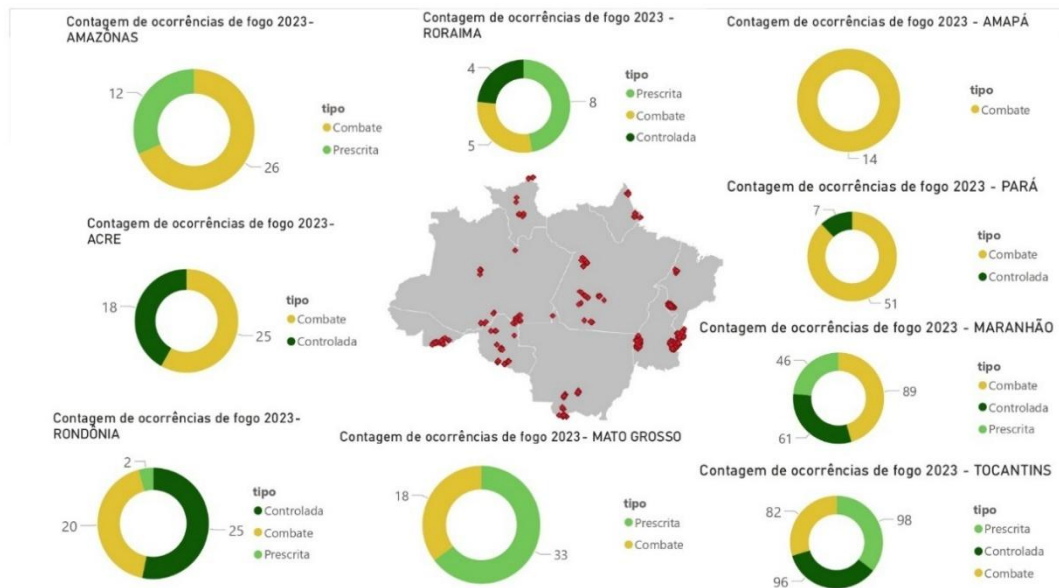


Figura 3 – Espacialização de ocorrências de fogo do ICMBio por Unidade Federativa no 2023.

Após a espacialização das ocorrências de fogo e sua inserção no *Postgresql*, foi realizado o cruzamento com os eventos de fogo, integrando todas as informações do acervo de dados da plataforma Painel do Fogo. De acordo com as regras de cruzamento definidas na metodologia, foi possível contabilizar que 740 eventos de fogo se sobrepuseram às ocorrências registradas no ano de 2023 (Figura 4).

Considerando a porcentagem e o cruzamento dos dados foi possível deduzir que 330 (44,59%) eventos de fogo do Painel cruzaram, estando relacionados com operações específicas de controle do fogo na Amazônia Legal. Já as atividades relacionadas com queimas controladas tiveram 211(28,51%) e as queimas prescritas 199 (26,89%) refletindo em um menor número de ocorrências que intersectaram com os eventos detectados no 2023




Figura 4 – Cruzamento das ocorrências de fogo do ICMBio com dados do Painel do Fogo.

Insights na Tipificação do Fogo para a Gestão do Fogo na Amazônia Legal

O impacto do uso do fogo nas UFs foi analisado pelo cruzamento dos eventos registrados no Painel do Fogo, permitindo identificar padrões e comparar a média dos atributos conforme o tipo de uso (combate, prescrita e controlado). Os gráficos de linha mostram os padrões de alguns atributos desse acervo em relação à tipificação do fogo.

Em relação à variável *persistência* de incêndios, verificou-se que, em média, Mato Grosso (MT) registrou 20 dias, Amapá (AP), 17,5 dias e Pará (PA), 6 dias (Figura 5a). Esse tempo médio reflete o período necessário para conter incêndios classificados como de combate nessas regiões. Nas áreas indígenas (Figura 5b), o Amapá teve a maior representatividade em acionamentos para combate, com 14 km² de áreas afetadas. Em contraste, no estado de Rondônia, a gestão do fogo ecológico por meio de queimas prescritas cobriu 7 km², ajudando a reduzir riscos e preservar a integridade ecológica do território.

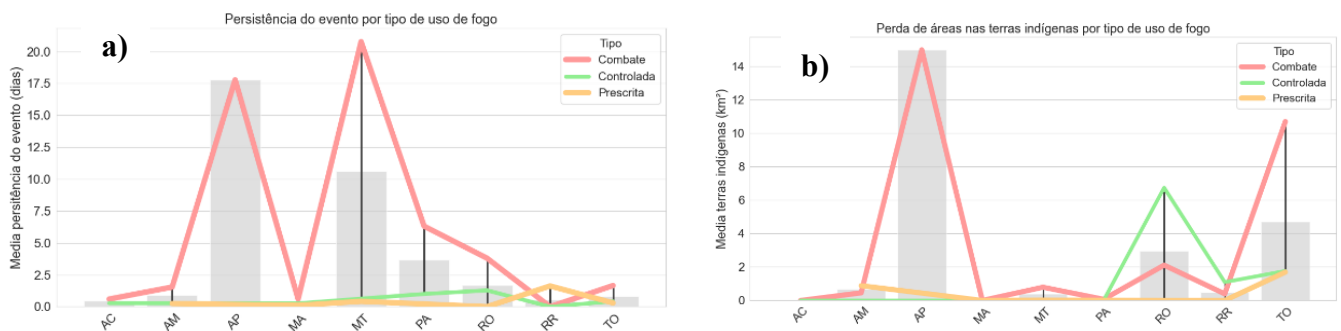


Figura 5 (a) Atividades de Fogo e a Média de Persistência (*persistenc*) dos Eventos de Fogo cruzados com as Ocorrências do ICMBio em 2023. (b) Média de perda de terras indígenas (*a_terr_in*) nos eventos de fogo cruzados com as ocorrências do ICMBio em 2023.

O cruzamento das queimas prescritas com os atributos dos eventos de fogo, evidenciou que uma redução de áreas atingidas por incêndios em 70 km², 90 km² e até 100 km² nos estados de MT, PA e RR, respectivamente (Figura 6a). Por sua vez, as áreas médias dos eventos de fogo correspondentes à área vetorial acumulada (Figura 6b) indicam que as queimadas prescritas abrangem 98 km² enquanto as queimadas controladas atingem cerca de 50 km, o que sugere que as práticas de gestão do fogo realizada pelos brigadistas refletiram de maneira positiva dentro das UCs contribuindo para a redução da área afetada e, conseqüentemente, para uma menor perda de cobertura florestal.




Figura 6 (a) Média de perda de áreas nas UCs (*areakm²_uc*) nos eventos de fogo cruzados com as ocorrências do ICMBio em 2023. (b) Média das áreas nos eventos de fogo (*area_km²*) cruzados com as ocorrências do ICMBio em 2023.

A partir das áreas do Cadastro Ambiental Rural(CAR) e áreas públicas intersectadas, foi possível interpretar que em Mato Grosso (MT), cerca de 1.000 km² das áreas do CAR e 157 km² de áreas públicas,

além de 50 km² no Amapá, foram afetadas por queimadas em 2023.(Figura 7a,7b), desta forma, estes resultados destaca a necessidade de políticas de prevenção para reduzir as perdas causadas pelas queimadas descontroladas e impulsionar práticas de manejo sustentável do fogo nas Ufs que ainda não estão sendo adequadamente gerenciadas.

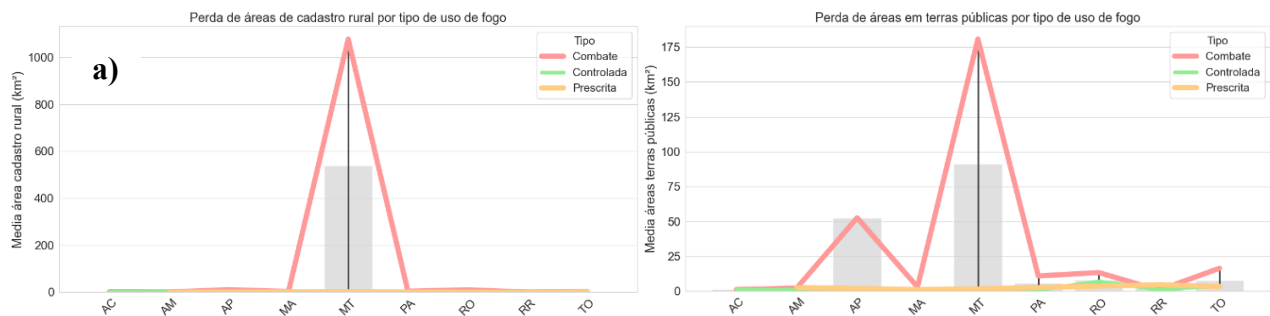


Figura 7 (a) Média de perda de áreas de cadastro rural (*area_car*) nos eventos de fogo cruzados com as ocorrências do ICMBio em 2023. (b) Média de perda nas terras públicas (*a_terr_pub*) nos eventos de fogo cruzados com as ocorrências do ICMBio em 2023.

Trabalhos como o de Dominguez et al. (2022) destacam que o uso de estratégias de manejo do fogo, contribuem para a mitigação das emissões de CO₂. Essa evidência encontra respaldo nos resultados desta pesquisa, uma vez que o cruzamento dos eventos de fogo com informações sobre queimadas prescritas e controladas indica uma redução significativa da área queimada e da extensão dos eventos em áreas sob manejo. Esses achados sugerem que práticas de gestão do fogo podem contribuir à diminuição das áreas queimadas e, conseqüentemente, favorecer a mitigação indireta das emissões de CO₂ associadas aos incêndios florestais.

Nesse sentido, Amapá (AP) e de Rondônia (RO) registraram reduções nas áreas queimadas da cobertura florestal, variando entre 40 km² e 100 km², devido ao uso de queimadas prescritas (Figura 8a). Além disso, a quantidade média de carbono orgânico armazenado na biomassa aérea das florestas variou entre os estados. No Acre (AC), por exemplo, o estoque de carbono florestal alcança quase 240 t/ha, enquanto no Pará (PA) é de 220 t/ha, em decorrência das práticas de queimadas controladas. Já no Amazonas (AM), as queimadas prescritas resultam em um estoque de 50 t/ha, enquanto em Rondônia (RO) esse valor chega a 100 t/ha (Figura 8b).

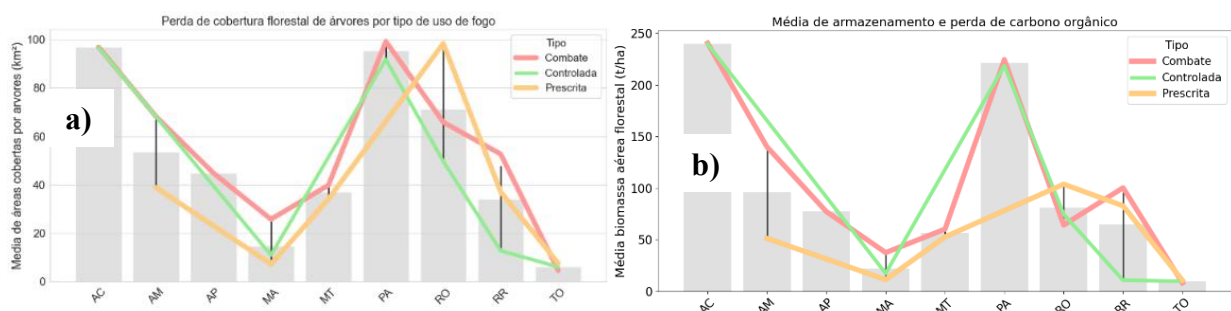


Figura 8 (a) Média das reduções de áreas queimadas na cobertura florestal (*tree_cover*) nos eventos de fogo cruzados com as ocorrências do ICMBio em 2023. (b) Média de armazenamento e perda de carbono orgânico florestal (*biomass_gs*) nos eventos de fogo cruzados com as ocorrências do ICMBio em 2023.

Implementação técnicas de Machine Learning para a tipificação do fogo do ICMBio

Uma vez realizado essas análises, foi realizado a normalização dos dados e identificadas as variáveis com maior contribuição por meio da Análise de Componentes Principais (PCA).

Assim, para o Componente 1, as variáveis selecionadas foram: *biomass_ag*, *biomass_gs* e *tree_cover*. No Componente 2, foi possível agrupar o maior número de variáveis: *Persistenc*, *qtd_detecc*, *area_km2*, *areakm2_uc*, *a_terr_pri*, *a_terr_pub*, *a_terr_unk* e *area_car*. Já no Componente 3, foram selecionadas as variáveis *deter_area* e *areakm2_in* (Tabela 4). Essa organização reflete a contribuição de cada variável para a explicação da variância nos diferentes componentes principais. No entanto as variáveis *deter_days* e *a_terr_unk* foram excluídas por apresentarem baixa contribuição na variabilidade do acervo de dados, além de alta correlação com outras variáveis, o que poderia comprometer a performance dos modelos de aprendizado de máquina.

Tabela 4 – Componentes que explicam a variabilidade do conjunto de dados resultante do cruzamento entre os eventos de fogo no painel e as ocorrências associadas

	% variância explicada pelo fator	% variância total	W (peso do componente)
Componente 1	13,728783	95,32	0,144
Componente 2	75,191922	95,32	0,789
Componente 3	6,408567	95,32	0,067

Otimização dos modelos :Método Holdout

Após a normalização dos dados e a seleção dos atributos a serem incluídos na modelagem, foi aplicada a técnica de *Holdout* para avaliar o desempenho dos modelos. Dessa forma, foram realizadas 100 repetições (Figuras 9a, 9b e 9c) em diferentes subconjuntos da base de dados resultante do cruzamento. Essa abordagem permitiu analisar, em um primeiro momento, a estabilidade e a consistência de cada modelo.

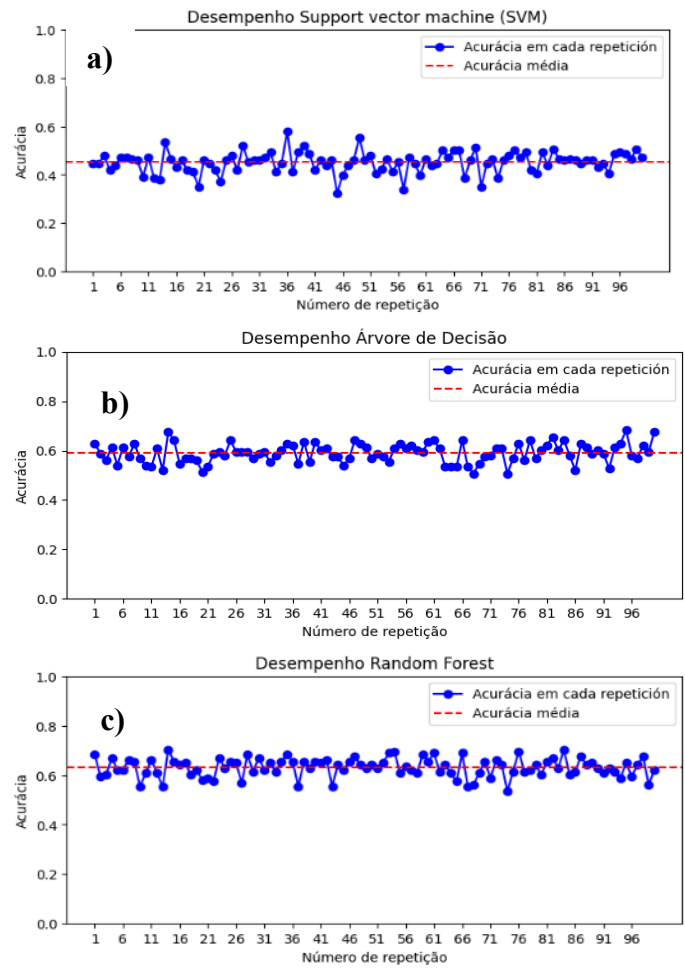


Figura 9. Interações do método *Holdout* para avaliar o desempenho do modelo de AD, SVM e RF.

Em síntese, foi possível interpretar que o modelo *Random Forest*, segundo as repetições, apresentou maior confiança para realizar estimações no conjunto de treinamento, com uma acurácia média de 0.630 e desvio padrão de 0.038 (Figura 20). Sendo possível evidenciar a consistência e a dispersão dos resultados, destacando a robustez do modelo em comparação aos demais.

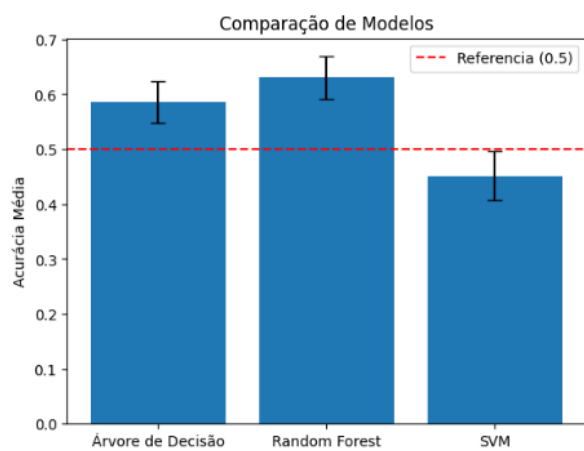


Figura 10 – Comparação do desempenho dos modelos de aprendizagem em relação à acurácia média.

Validação cruzada

Nesta pesquisa, devido às limitações no número de dados obtidos do cruzamento, utilizou-se a validação cruzada para garantir que cada instância fosse empregada tanto no treinamento quanto no teste. O conjunto de dados foi dividido em 5 folds, onde, a cada iteração, um foi usado para teste e os demais para treinamento. Diferentes hiperparâmetros foram otimizados para avaliar a acurácia média dos modelos, cujos resultados são apresentados na Tabela 4.

Após utilizar a técnica de *validação cruzada*, o modelo *Random Forest* apresentou a maior acurácia, com uma média de 0,616 e um desvio padrão de 0,0025, ratificando sua robustez para realizar generalizações na tipificação de fogo. Vale salientar que o SVM foi o modelo com maior desvio padrão, o que sugere maior sensibilidade às variações dos dados de treinamento e uma tendência ao sobreajuste (Tabela 4).

Tabela 4 – Otimização de parâmetros utilizados para a validação dos dados de teste.

Aprendizado de Máquina.	Hiperparâmetros	Acurácia Média	Desvio Padrão
<i>Vector Support Machine (SVM)</i>	C= 10, kernel= 'rbf', probability = True	0.504	0.047
	C= 5, kernel= 'rbf', probability = True	0.499	0.052
	C= 0,1, kernel= 'rbf', probability = True	0.524	0.048
<i>Decision Tree (DT)</i>	Random State = 42, min_samples_split = 12, max_features = 15, max_depth= 15	0.537	0.047
	Random State = 42, min_samples_split = 10, max_features = 20, max_depth= 8	0.530	0.052
	Random State = 42, min_samples_split = 10, max_features = 13, max_depth= 10	0.541	0.045
<i>Random Forest (RF)</i>	Random State = 42, max_depth= 16, n_estimators= 100, min_samples_split= 8, max_features = 10	0.603	0.035
	Random State = 42, max_depth= 50, n_estimators= 100, min_samples_split= 10, max_features = 15	0.587	0.031
	Random State = 42, max_depth= 80, n_estimators= 100, min_samples_split= 10, max_features = 10	0.616	0.025

Após a implementação do procedimento anterior, foram realizadas generalizações no conjunto de dados de teste, ou seja, nos dados não vistos, obtendo-se os seguintes resultados (Tabela 5).

Nesse sentido, os resultados permitiram classificar a categoria de pertencimento ao tipo de uso de fogo, com base nas características cruzadas nos eventos de fogo.

Foram considerados 111 instancias na fase de teste, o tipo de ocorrência *combate* apresentou alta precisão nos modelos testados. Para o SVM, a precisão alcançada foi de 0,89, enquanto para o RF, o valor foi de 0,90. Já na categoria de queimadas prescritas e controladas, a maior precisão foi obtida nos modelos DT e RF. Esses resultados refletem a proporção de observações corretamente classificadas pelos modelos com base nos dados de teste (ZHANG et al., 2021; SUN et al., 2022).

O modelo RF apresentou o maior *recall*, indicando uma melhor capacidade de classificar corretamente os tipos de fogo, com os seguintes valores: combate (0,71), prescrita (0,80) e controlada (0,78). Além disso, atingiu uma acurácia de 76%. Esse resultado evidencia a eficácia do método proposto para a tipificação do tipo de fogo, considerando as características intrínsecas dos eventos e a estratégia de cruzamento de dados adotada, em conformidade com os objetivos deste trabalho.

Tabela 5 – Desempenho dos modelos de aprendizado de máquina no conjunto de Teste

		Métricas	Precisão	Recall	F1-Score
		SVM			
Tipo de ocorrência de fogo	Combate		0.89	0.51	0.65
	Prescrita		0.59	0.57	0.58
	Controlada		0.44	0.75	0.56
	Acurácia (%)	59 %			
					DT
	Combate		0.70	0.78	0.74
	Prescrita		0.62	0.53	0.57
	Controlada		0.52	0.50	0.51
	Acurácia (%)	63 %			
					RF
	Combate		0.90	0.71	0.80
	Prescrita		0.69	0.80	0.74
	Controlada		0.68	0.78	0.72
Acurácia (%)	76%				

Para avaliar a qualidade do modelo RF, a métrica *Receiver Operating Characteristic* (ROC) e *Area Under the Curve* (AUC) permitiu identificar que o tipo de ocorrência prescrita apresentou o maior desempenho preditivo (AUC = 0,91), superando os outros tipos de ocorrência (Figura 11a). Os valores de AUC para todas as classes variaram entre 0,8 e 0,9, o que demonstra que o desempenho preditivo do modelo é muito bom, conforme estabelecido na literatura. (CHEN et al., 2018; AKINCI e ZEYBEK et al., 2021).

Ja na Figura 11b, se evidenciou que as classes 'Combate' e 'Prescrita', com AUC de 0,84 e 0,79, respectivamente, apresentaram uma boa capacidade de distinguir os eventos do Painel do Fogo pertencentes nessas categorias. No entanto, a classe 'Controlada', com AUC de 0,67, enfrentou mais dificuldades em generalizar os casos dessa categoria. Em síntese, a classe *Controlada* nesta pesquisa revelou ser mais difícil de diferenciar das demais, seja devido à similaridade com outras classes, pela sub-representação nos dados ou pela maior complexidade intrínseca de seus padrões, o que dificultou a previsão.

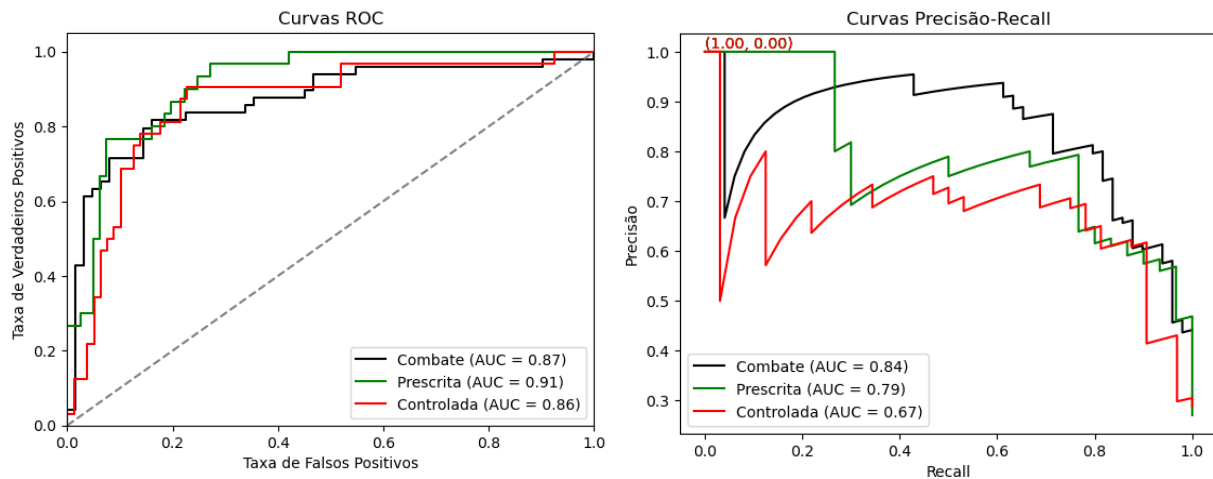


Figura 11 (a) ROC (*Receiver Operating Characteristic*) para o modelo RF. (b) AUC (*Area Under the Curve*) para o modelo RF.

Previsões na tipificação do Fogo

Após a modelagem, foram realizadas algumas previsões com o objetivo de identificar acertos e erros de classificação. Ressalta-se que, mesmo sendo a categoria *Combate* a de maior acurácia no RF, optou-se por apresentar um exemplo de previsão incorreta dessa classe, assim como das demais categorias de queimadas, com fins de visualização dos resultados.

Note-se que na primeira previsão o modelo classificou corretamente tipo de queimadas (Figura a1), em contraste na segunda previsão, o modelo classificou como *prescrita* (Figura 12 b1), evidenciando um erro na previsão do modelo. Da mesma forma, foram realizadas previsões de fogo nas outras categorias, *Controlada* e *Prescrita*.

Neste sentido, a ocorrência real faz referência aos pontos de ocorrência de fogo, obtidos pelos brigadistas do ICMBio em campo (Figura 12 a, b, c, d, e, f). Já as previsões resultantes indicam a ocorrência de fogo prevista ou classificada pelo RF. De maneira ilustrativa, apresentam-se os eventos de fogo nas previsões com intuito de evidenciar o tamanho detectado dos eventos de fogo do Painel correspondente a essa ocorrência. Vale salientar que foi esse tipo de dado que foi cruzado com as ocorrências nesta pesquisa. (Figura 12 a1, b1, c1, d1, e1, f1).

Os resultados obtidos com o modelo Random Forest (RF) são coerentes com a lógica operacional adotada pelas brigadas, uma vez que eventos com maior persistência e maior número de focos de calor demandam, em geral, ações de combate mais intensivas. Esse comportamento reforça a capacidade do modelo em capturar padrões relevantes associados ao tamanho dos eventos de fogo cruzados nas com as ocorrências. Resultados semelhantes foram observados por Santos et al. (2020), que demonstraram que atributos derivados de focos de calor e variáveis ambientais são capazes de explicar padrões de ocorrência de incêndios e contribuir para o desenvolvimento de modelos preditivos eficazes no contexto brasileiro.

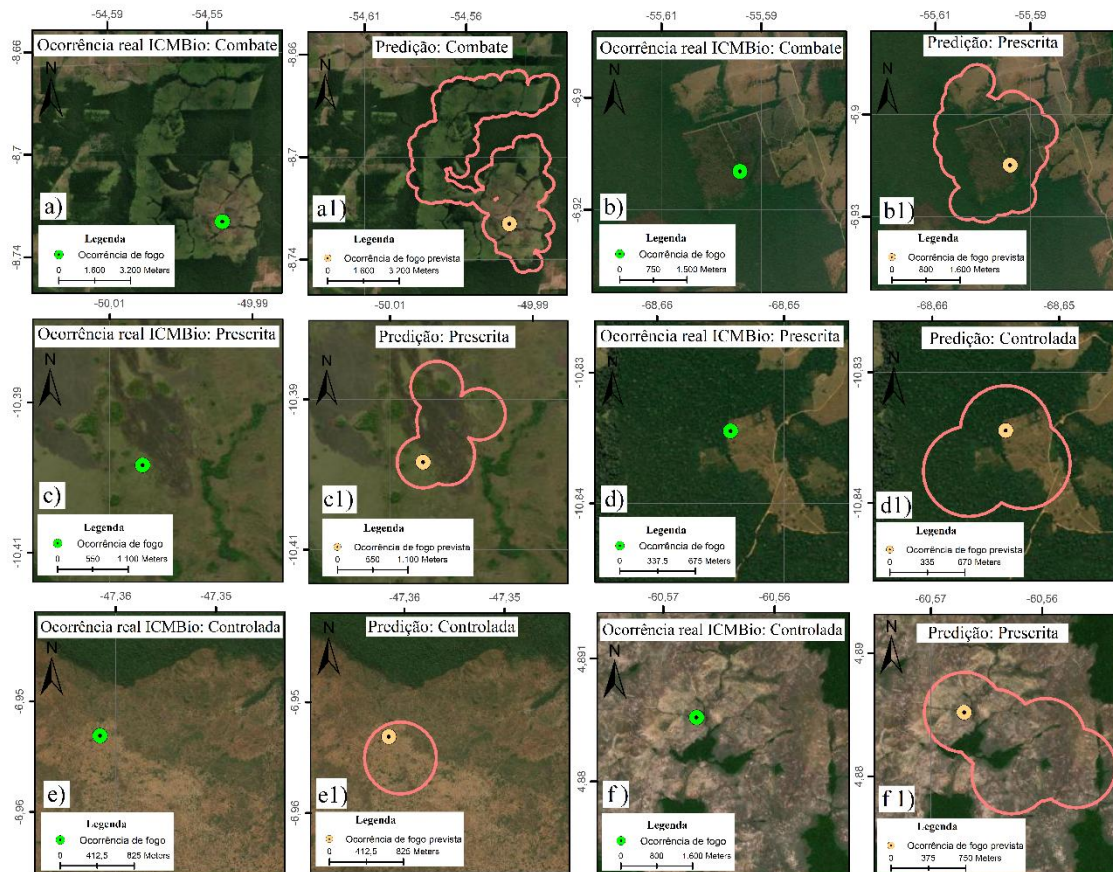


Figura 12 – (a-a1) Reserva Biológica Nascentes da Serra do Cachimbo, Altamira - Pará, 16 de agosto de 2023. (b-b1) Floresta Nacional do Jamanxim, Novo Progresso - Pará, 18 de agosto de 2023. (c-c1) Parque Nacional do Araguaia, Pium -Tocantins, 30 de junho de 2023. (d-d1) Reserva Extrativista Chico Mendes, Epitaciolândia - Acre, 21 de junho de 2023. (e-e1) Parque Nacional da Chapada das Mesas, Carolina – Maranhão, 10 de maio de 2023. (f-f1) Parque Nacional do Monte de Roraima, Uiramutã-Roraima, 3 de julho de 2023.

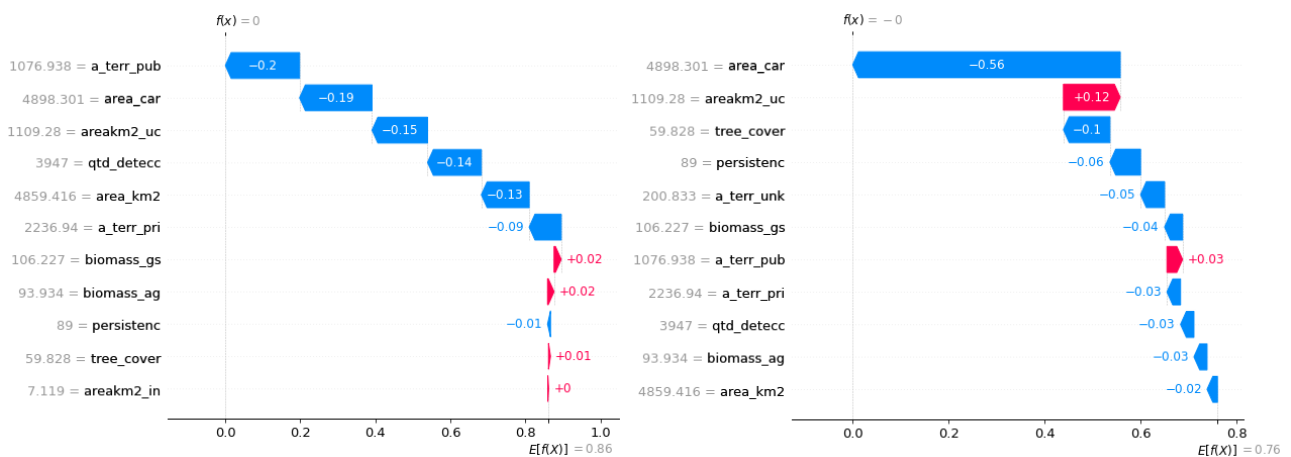
Análises de importância valores SHAP (Shapley Additive Explanations)

No modelo RF (Figura 13c), foram identificadas as variáveis *qtd_detecc*, *área_km2*, *persistência* e *biomassa_gs* como contribuições negativas, sugerindo que valores elevados dessas variáveis reduzem a probabilidade de o modelo classificar um evento como algum tipo de queimada. Essa interpretação pode ser explicada, por exemplo, pelo fato de que um alto número de focos de calor (*qtd_detecc*) diminui a probabilidade de classificação como 'prescrita' e aumenta a probabilidade de classificação como 'combate', uma vez que focos mais intensos podem indicar maior a necessidade de intervenção das brigadas de combate.

No entanto, variáveis como a *persistência* no incêndio sugerem que um maior tempo de duração do evento de fogo pode ser um fator que reduz a classificação como "prescrita" ou "controlada", levando à classificação como "combate", pois eventos com maior persistência acarretam maior tamanho e duração do incêndio (Mojica *et al.*, 2024). Esse comportamento sugere que o modelo priorizou atributos associados à intensidade e à duração do fogo, em detrimento do contexto operacional do evento.

Variáveis associadas à intensidade, à duração e à extensão espacial dos eventos de fogo já têm sido consideradas na literatura. Aragão et al. (2008) mencionam que o número de focos de calor, a persistência temporal e a área afetada estão diretamente relacionadas à severidade dos incêndios e à necessidade de ações de combate mais intensivas. Nesse sentido, os resultados deste trabalho indicam que os modelos foram capazes de capturar padrões que refletem a lógica da dinâmica dos incêndios florestais no Brasil, nos quais eventos mais extensos e persistentes tendem a ser classificados como ocorrências que demandam intervenção direta de combate ao fogo, em detrimento de queimadas prescritas ou controladas.

As contribuições positivas, representadas na cor rosada, indicam que variáveis como *biomassa_gs* e *tree_cover* aumentam a probabilidade de um evento de fogo ser classificado em uma determinada categoria. Esses resultados estão em concordância com estudos prévios, e amplamente discutidas na literatura, conforme apresentado por Nepstad et al. (1994) e Aragão et al. (2014) destacam que a relação entre o acúmulo de biomassa, a cobertura florestal e a persistência dos incêndios são fatores que contribuem para o aumento do potencial de propagação do fogo. Nesse contexto, tais variáveis devem continuar sendo consideradas no processo de modelagem, uma vez que ampliam a capacidade preditiva na distinção da tipificação do uso do fogo.



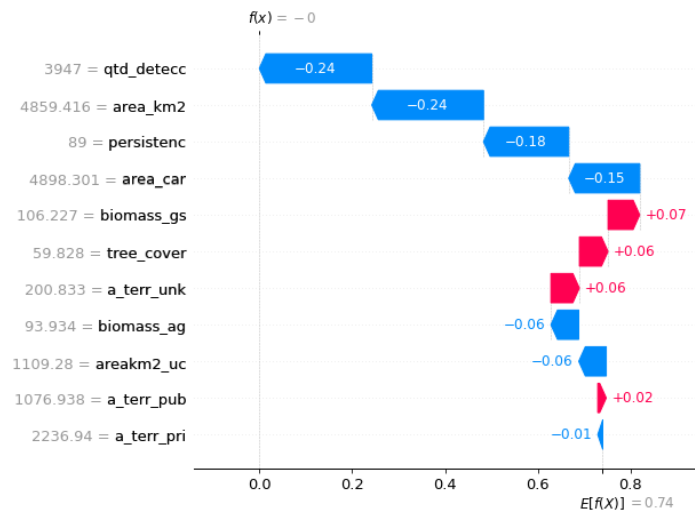


Figura 13 (a) Gráfico contribuições individuais de variáveis para o modelo SVM. (b) Gráfico contribuições individuais de variáveis para o modelo DT. (c) Gráfico das contribuições individuais das variáveis para o modelo com melhor desempenho na tipificação de queimadas utilizando RF.

Considerações Finais

Esta pesquisa possibilita compreender como a gestão do uso do fogo pode contribuir em diferentes momentos do MIF, ao identificar como os diversos tipos de fogo impactam cada região da Amazônia Legal de maneira distinta. Essa interpretação foi viabilizada pelo uso da metodologia de cruzamento das ocorrências de fogo com os eventos registrados no Painel do Fogo do CENSIPAM, oferecendo insights para medidas voltadas ao entendimento do uso do fogo e à implementação de estratégias de manejo e prevenção.

A coleta de dados sobre as ocorrências e os atores envolvidos na gestão do fogo, deve ser uma tarefa constante permitindo cruzamentos mais eficazes com os eventos de fogo detectados pelo Painel do Fogo. Por tanto é fundamental fortalecer os canais de comunicação na solicitação de dados de ocorrências, a fim de garantir um acesso contínuo e assertivo aos dados.

O uso de técnicas de aprendizado de máquinas possibilitou a classificação das categorias de uso do fogo com base nas variáveis cruzadas nos eventos de fogo. O modelo RF teve melhor desempenho, com uma acurácia global de 76%. As queimadas 'Combate' e 'Prescrita', com AUC de 0,84 e 0,79, demonstraram maior poder preditivo em comparação à 'Controlada'. Como esta foi a primeira metodologia aplicada na tipificação do fogo, recomenda-se a exploração de outros modelos para aprimorar a classificação e aumentar a acurácia dos resultados.

Os valores SHAP mostraram que, quanto maior a área afetada dos eventos de fogo intersectados com as ocorrências em termos de área atingida, melhor foi a separação das classes de fogo. Em resumo, as variáveis *biomassa_ag*, *tree_cover* e *terr_unk* do modelo RF foram as que mais contribuíram positivamente para aumentar a probabilidade de classificação da ocorrência como algum tipo de queimada, com contribuições de 0,07, 0,06 e 0,06 unidades, respectivamente.

Espera-se que esta metodologia ofereça um panorama para as instituições interessadas na gestão do fogo. Uma vez, que foi possível identificar, além das áreas com maior número de eventos de fogo combatidos por brigadas, permitiu compreender como as práticas de manejo florestal de subsistência e o manejo no uso de queimadas prescritas e controladas podem contribuir para a prevenção de incêndios

florestais e redução de queimadas descontroladas. Sendo que, esses resultados foram especialmente evidenciados nos estados do Pará (PA) e Rondônia (RO).

A metodologia pode ser utilizada pelas instituições que visam o controle e monitoramento do fogo, pois classificar o tipo de queimada associado a um evento de fogo proporcionaria um mecanismo de alerta prévio à ativação ou acionamento das brigadas de combate, sendo fundamental para direcionar recursos de forma eficiente. Isso pode melhorar a gestão e a alocação de recursos das brigadas, especialmente em áreas onde o deslocamento das equipes é mais difícil, otimizando os recursos econômicos e operacionais disponíveis.

Referências

ALENCAR, A; MOUTINHO, P; ARRUDA, V; SILVÉRIO, D. Amazônia em chamas o fogo e o desmatamento em 2019 e o que vem em 2020. *Nota técnica*, n. 3, 2020.

ALENCAR, A; MARTENEXEN, L; GOMES, J; MORTON, D; BRANDO, P. Amazônia em chamas: Entendendo a relação entre o fogo e desmatamento em 2023. *Nota Técnica*, n 12 .2024.

ANTUNES, E. H.; RIBEIRO, V. R. S.; DA SILVA NOGUEIRA, D. F.; CUNHA, P., BERNINI, H.; DE FARIA, D. R. Mapeamento de Áreas Espúrias para o Painel do Fogo. XX Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 2 e 5 de abril, 2023, Florianópolis. 2023.

ARAGÃO, L; MALHI, Y; BARBIER, N; LIMA, A; SHIMABUKURO, Y; ANDERSON, L; SAATCHI, S. Interactions between rainfall, deforestation and fires during recent years in the Brazilian Amazonia. *Philosophical Transactions of the Royal Society B: Biological Sciences*, v. 363, 1779-1785.2008.

ARAGÃO, L. E; POULTER, B; BARLOW, J. B; ANDERSON, L. O; MALHI, Y; SAATCHI, S; GLOOR, E. (2014). Environmental change and the carbon balance of Amazonian forests. *Biological Reviews*, 89(4), 913-931.

ALKAN, H; AKINCIB, H; ZEYBECK, M. Comparison of diverse machine learning algorithms for forest fire susceptibility mapping in Antalya, Türkiye. *ScienceDirect, Advances in Space Research*, p 0273-1177.2024.

AKINCI H; ZEYBEK, M. Comparing classical statistic and machine learning models in landslide susceptibility mapping in Ardanuc (Artvin). Turkey. *Nat. Hazards*. v 108, p. 1515–1543. 2021.

BREIMAN, L. Random forests. *Machine learning*, v. 45, p. 5-32, 2001.

BARLOW, J; BERENQUER, E; CARMENTA R; FRANÇA, F. Clarifying Amazonia's burning crisis. *Global Change Biology*, v 26, p 319-321. 2020.

CENSIPAM. Centro Gestor e Operacional do Sistema de Proteção da Amazônia. Disponível em: Painel do Fogo. <https://panorama.sipam.gov.br/painel-do-fogo/> Acesso em: 20 jan 2025.

CHEN, W; PENG, J; HONG, H; SHAHABI, H; PRADHAN, B; LIU, J; DUAN, Z. (2018). Landslide susceptibility modelling using GIS-based machine learning techniques for Chongren County, Jiangxi Province, China. *Science of the total environment*, v 626, p. 1121-1135.2018.

Conselho Nacional do Meio Ambiente. Resolução CONAMA nº 11, Diário Oficial da União, Seção 1: 13661. Brasília, DF, 14 de dezembro de 1988. Disponível em: https://conama.mma.gov.br/?option=com_sisconama&task=arquivo.download&id=75. Acesso em: 10 jun. 2024.

Conselho Nacional de Justiça (CNJ). Crimes Ambientais na Amazônia Legal: A Atuação da Justiça nas Cadeias de Lavagem de Bens e Capitais, Corrupção e Organização Criminosa. 2024. Disponível em: <https://bibliotecadigital.cnj.jus.br/xmlui/handle/123456789/824>.

DE ANDRADE, A; RAMOS, R; SANO, E; LIBONATI, R; SANTOS, F; RODRIGUES, J; GIONGO, M; DA FRANCA, R; LARANJA, R. Implementation of fire policies in Brazil: An assessment of fire dynamics in Brazilian savanna. v. 13, p. 11532. 2021.

Decreto nº 84.017, de 21 de setembro de 1979. Diário Oficial da União, Seção 1: 13785. Disponível em: https://www.planalto.gov.br/ccivil_03/atos/decretos/1979/d84017.html. Acesso em: 3 mai. 2024.

DIAS, F; SUHADOLNIK, N; CAMARGO, H; DA SILVA, S. Predicting the pulse of the Amazon: Machine learning insights into deforestation dynamics. *Journal of Environmental Management*, v 362, p. 121359. 2024.

DONG, H; WU, H; SUN, P; DING, Y; Wildfire prediction model based on spatial and temporal characteristics: a case study of a wildfire in Portugal's Montesinho Natural Park. *Sustainability*. v14, p. 10107.2022.

DOMINGUEZ, D; DEL VILLAR; PANTOJA, O; GONZÁLEZ M. Forecasting amazon rain-forest deforestation using a hybrid machine learning model. *Sustainability*, v 14, p 691. 2022.

FÁVERO, L; FÁVERO, P. Análise de dados: técnicas multivariadas exploratórias com SPSS e STATA. *Elsevier Brasil*, 2017.

FERRO, P; DE MEDEIROS, T; DUTRA, D; MATAVELI G., ANDERSON, L; PESSÔA, C; DE SOUZA. Detecção de áreas queimadas baseado no modelo linear de mistura espectral aplicado em cubo de dados CBERS-4 e CBERS-4a no Oeste de Rondônia, Brasil. *Simpósio Brasileiro de Sensoriamento Remoto. Florianópolis*. 2023.

HAIR, J. F. Análise multivariada de dados. Bookman editora, 2009.

HERRMANN, P; NASCIMENTO, V; CASAGRANDE, F; DE FREITAS, W; KLUG, A. Spatial modeling of fire in the atlantic forest considering future climate change scenarios in Rio Grande do Sul state–Brazil. *Journal of South American Earth Sciences*, v. 131, p. 104614, 2023.

HOMMA, A. K. O. Amazônia: a civilização do fogo. In: Da tradição das queimadas à agricultura sustentável na Amazônia. Embrapa, 2020.

ICMBio. Instituto Chico Mendes de Conservação da Biodiversidade. 2022. Portaria ICMBio nº 1.150, de dezembro de 2022. Diário Oficial da União, ed. 229, Seção 1: 148. Disponível em: <https://www.in.gov.br/en/web/dou/-/portaria-icmbio-n-1.150-de-6-de-dezembro-de-2022-448579352>. Acesso em: 10 mai. 2024.

KAVZOGLU, T; COLKESEN, I. A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, v 11, p. 352-359. <https://doi.org/10.1016/j.jag.2009.06.002> , 2009.

_____. Lei nº 4.771, de 15 de setembro de 1965. Institui o novo Código Florestal. Diário Oficial da União: Brasília, DF, 15 de setembro de 1965. Seção 1: 9529. Disponível em: https://www.planalto.gov.br/ccivil_03/LEIS/L4771impressao.htm. Acesso em: 10 maio 2024.

_____. Lei nº 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa. Diário Oficial da União: Brasília, DF, 25 de maio de 2012. Seção 1: 1. https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112651.htm. Acesso em: 10 maio 2024.

_____. Lei nº 1.818, de 2022. Senado Federal. Política Nacional de Manejo Integrado do Fogo. Brasília, DF, 31 de agosto de 2024. Disponível em: <https://legis.senado.leg.br/norma/39388600>. Acesso em: 15 setembro 2024.

_____. Lei nº 14.944, de 31 de julho de 2024. Institui a Política Nacional de Manejo Integrado do Fogo e altera as Leis nºs 7.735, de 22 de fevereiro de 1989, 12.651, de 25 de maio de 2012 (Código Florestal), e 9.605, de 12 de fevereiro de 1998 (Lei dos Crimes Ambientais). Diário Oficial da União: Brasília, DF, 31 de agosto de 2024. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2023-2026/2024/lei/L14944.htm. Acesso em: 23 de outubro de 2024.

LI, Y; FENG, Z; CHEN, S; ZHAO, Z; WANG, F. Application of the artificial neural network and support vector machines in forest fire prediction in the Guangxi Autonomous Region, China. *Discrete Dyn. Nat. Soc.* p. 612650. 2020.

LUNDBERG, S. M; LEE, S. A. Unified approach to interpreting model prediction. In: 31st Conference on Neural Information Processing Systems. 2017.

MAILLARD, G; ARLOT, S; LERASLE, M. Aggregated hold-out. *Journal of Machine Learning Research*, v. 22, n. 20, p. 1-55, 2021.

MATAVELI, G; JONESM. W; CARMENTA, R; SANCHEZ, A; DUTRA, D; CHAVES, M; ARAGÃO, L. Deforestation falls but rise of wildfires continues degrading Brazilian Amazon forests. *Global change biology*, v 30, p 17202. 2024.

NEPSTAD, D. C; DE CARVALHO, C. R; DAVIDSON, E. A; JIPP, P. H; LEFEBVRE, P. A; NEGREIROS, G. H; VIEIRA, S. (1994). The role of deep roots in the hydrological and carbon cycles of Amazonian forests and pastures. *Nature*, 372(6507), 666-669.

MOJICA, J; BERNINI H; DE FARIA, D; ANTUNES E; SIQUEIRA, L; SOUZA, C; FONTOURA, S; RODOVALHO, F. Spatialization of Fire Occurrences in Brazil within the context of the fire events detected by the fire panel. *RAEGA - O Espaço Geográfico Em Análise*, v 60, p 131-158. 2024.

PANG, Y., LI, Y., FENG, Z., FENG, Z; ZHAO, Z; CHEN, S; ZHANG, H. Forest fire occurrence prediction in China based on machine learning methods. *Remote Sensing*, v 14, p 5546. 2022.

PÉREZ, L; DELEGIDO, J; RIVERA-CAICEDO, J; VERRELST, J. Analysis of cross-validation methods for robust retrieval of biophysical parameters. *Revista De Teledetección*, v. 44, p.55-65. 2015.

PEDREGOSA, F; VAROQUAUX, G; GRAMFORT, A; MICHEL, V; THIRION, B; GRISEL, O; DUCHESNAY, É. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v 12, p 2825-2830.2011.

Presidencia da República. Decreto nº 2.661, de 8 de julho de 1998. Diário Oficial da União, Seção 1: 1. Disponível em: https://www.planalto.gov.br/ccivil_03/decreto/d2661.htm. Acesso em: 3 mai. 2024.

POSTGRESQL DEVELOPERS. The World's Most Advanced Open-Source Relational Database. 2023. Disponível em: <https://www.postgresql.org/> Acesso em: 4 de maio. 2024.

REDDINGTON, C. L. et al. *Air quality and human health improvements from reductions in deforestation-related fire in Brazil*. Nature Geoscience, 2015.

REDDINGTON, C; BUTT, W; RIDLEY, A; ARTAXO, P; MORGAN, T; COE, H; SPRACKLEN, V. Air quality and human health improvements from reductions in deforestation-related fire in Brazil. *Nature Geoscience*, v 8, p 768-771. 2015.

ROCHA, S; RAUBER, L. Amazônia Legal Brasileira: A incidência de focos de calor entre os anos de 2001 e 2020 e a correlação com o desmatamento de corte raso. *Revista Equador*, v 12, p 199-226.2023.

SANTOS, E. E. D; SENA, N. C; BALESTRIN, D; FERNANDES FILHO, E. I; COSTA, L. M. D; ZEFERINO, L. B. (2020). Prediction of burned areas using the random forest classifier in the Minas Gerais state. *Floresta e Ambiente*, 27(3).

SOARES, L; DA SILVA SANTOS, A; LAMEIRA, N; Manejo comunitário de recursos naturais: uma revisão de literatura. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, v 8, p 93-109. 2022.

SOUZA, C. A. et al. *Serviços Ecossistêmicos da Amazônia Brasileira*. 2024. Disponível em: <https://periodicos.ufpe.br/revistas/index.php/rbgfe/article/view/256805>

SUN, Y; LIN, H; XU, S. A. Forest Fire Susceptibility Modeling Approach Based on Light Gradient Boosting Machine Algorithm. *Remote Sensing*. v 14, p 4362. 2022.

XU, W; LIU, Y; VERAVERBEKE, S; WU, W; DONG, Y; LU, W. Active fire dynamics in the Amazon: new perspectives from high-resolution satellite observations. *Geophysical Research Letters*, v 48. 2021.

ZHANG, G., WANG, M., LIU, K. Deep neural networks for global wildfire susceptibility modelling. *Ecol. Indic.* v 127. p 107735. 2021.

Contribuição dos autores

J.P., T.F.B. e P.B.H. contribuíram para a concepção do estudo, desenho metodológico, desenvolvimento e aprovação final do manuscrito. D.C. foram responsáveis pela curadoria e processamento de dados, visualização, redação e elaboração do manuscrito. C.S.S. contribuiu para a revisão, validação e aprovação final do manuscrito.

Conflito de interesses

Os autores declaram que não há conflitos de interesse relacionados a este trabalho.

Disponibilidade de dados

Os dados que apoiam os resultados deste estudo estão disponíveis mediante solicitação aos autores.

Agradecimentos

O presente trabalho foi realizado no âmbito do projeto Painel do Fogo, com apoio do Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM), por meio da bolsa de pesquisa do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (processo: 380182/2024-6, Categoria: DTI-B – B). Agradecemos também ao Laboratório de Imagens, Sinais e Acústica (LISA) da Universidade de Brasília (UnB) e à Coordenação de Manejo Integrado do Fogo (CEMIF/ICMBio) pelo fornecimento dos dados.

Este preprint foi submetido sob as seguintes condições:

- Os autores declaram que os necessários Termos de Consentimento Livre e Esclarecido de participantes ou pacientes na pesquisa foram obtidos e estão descritos no manuscrito, quando aplicável.
- Os autores declaram que a elaboração do manuscrito seguiu as normas éticas de comunicação científica.
- Os autores declaram que estão cientes que são os únicos responsáveis pelo conteúdo do preprint e que o depósito no SciELO Preprints não significa nenhum compromisso de parte do SciELO, exceto sua preservação e disseminação.
- Os autores declaram que os dados, aplicativos e outros conteúdos subjacentes ao manuscrito estão referenciados.
- O manuscrito depositado está no formato PDF.
- Os autores declaram que a pesquisa que deu origem ao manuscrito seguiu as boas práticas éticas e que as necessárias aprovações de comitês de ética de pesquisa, quando aplicável, estão descritas no manuscrito.
- Os autores declaram que uma vez que um manuscrito é postado no servidor SciELO Preprints, o mesmo só poderá ser retirado mediante pedido à Secretaria Editorial do SciELO Preprints, que afixará um aviso de retratação no seu lugar.
- Os autores concordam que o manuscrito aprovado será disponibilizado sob licença [Creative Commons CC-BY](#).
- O autor submissor declara que as contribuições de todos os autores e declaração de conflito de interesses estão incluídas de maneira explícita e em seções específicas do manuscrito.
- Os autores declaram que o manuscrito não foi depositado e/ou disponibilizado previamente em outro servidor de preprints ou publicado em um periódico.
- Caso o manuscrito esteja em processo de avaliação ou sendo preparado para publicação mas ainda não publicado por um periódico, os autores declaram que receberam autorização do periódico para realizar este depósito.
- O autor submissor declara que todos os autores do manuscrito concordam com a submissão ao SciELO Preprints.