

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 ¹, Tássia Fraga Belloli ², Pamela Boelter Herrmann ³, Deyvis Cano ⁴,
Camila Souza Silva ⁵

¹Doutorando em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Brasil. (jack.pastrana@ufrgs.br)

²Doutora em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Brasil. (tassia.belloli@ufrgs.br)

³Doutorando em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Brasil. (pamela.herrmann@ufrgs.br)

⁴Doutorando em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Brasil. (deyvis.cano@ufrgs.br)

⁵Especialista em Ciências Florestais, Universidade de Brasília, Brasil. (camila.souza.terceirizada@ibama.gov.br)

Histórico do Artigo: Submetido em: 02/02/2026 – Revisado em: 27/02/2026 – Aceito em: 06/03/2026

Pesquisa em Preprint em: <https://preprints.scielo.org/index.php/scielo/preprint/view/14897> (SciELO Preprints)

RESUMO

Esta pesquisa tem como objetivo compreender os diferentes usos do fogo na gestão territorial, por meio da análise das queimas prescritas, controladas e de combate, cruzadas com dados do Painel de Fogo do CENSIPAM referentes ao ano de 2023. No âmbito deste estudo em específico, foi realizada uma investigação na Amazônia Legal brasileira, conforme delimitação administrativa oficial, abrangendo os estados do Acre, Amapá, Amazonas, Pará, Rondônia, Roraima, Tocantins, Mato Grosso e parte do Maranhão. Para isso, foram utilizados os eventos de fogo registrados em 2023, obtidos a partir da plataforma Painel do Fogo, que integrou uma base de dados com informações ambientais e socioespaciais, ampliando a capacidade de caracterização dos eventos. Esses dados foram cruzados com os registros das ocorrências de queimas prescritas, controladas e de combate realizadas pelos brigadistas do ICMBio no mesmo ano. A estratégia metodológica adotada considerou técnicas de aprendizado de máquina para realizar previsões e gerar insights sobre os impactos do uso do fogo nas Unidades Federativas (UFs). O modelo Random Forest apresentou a maior acurácia global (76%). As classes de queima de combate e prescrita alcançaram as maiores precisões (0,90 e 0,69, respectivamente), enquanto as curvas ROC e os valores de AUC indicaram boa capacidade de generalização para essas classes (0,84 e 0,79). Em contraste, a classe de queima controlada apresentou menor desempenho na generalização. As análises por Shapley Additive Explanations (SHAP) destacaram variáveis como biomassa e áreas sem fiscalização como fatores relevantes na modelagem da tipificação das ocorrências de fogo.

Palavras-chave : Aprendizado de máquina, Tipificação de fogo, Amazônia Legal, 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

ABSTRACT

This study seeks to investigate the different uses of fire in territorial management by analyzing prescribed, controlled, and suppression burns, combined with data from the Fire Panel of the Amazon Protection System Operational and Management Center (CENSIPAM) for the year 2023. The research was carried out in the Brazilian Legal Amazon, following the official administrative boundaries, covering the states of Acre, Amapá, Amazonas, Pará, Rondônia, Roraima, Tocantins, Mato Grosso, and part of Maranhão. Fire events recorded in 2023 were retrieved from the Fire Panel platform, which compiles a database of environmental and socio-spatial variables, thereby enabling a more comprehensive characterization of fire occurrences. These data were integrated with records of prescribed, controlled, and suppression burns conducted by ICMBio brigades during the same period. The methodological framework was based on machine learning techniques to generate predictive models and provide insights into the impacts of fire use across the Brazilian Federative Units (states). The Random Forest model achieved the highest overall accuracy (76%). Suppression and prescribed burns

Pastrana, J.E., Belloli, T. F., Herrmann, P B., Cano, D., Silva, C. S. (2026). Predição e tipificação do uso do fogo na região da Amazônia Legal no Brasil: estudo com base nos eventos detectados pelo Painel do Fogo. **Revista Brasileira de Sensoriamento Remoto**, v.7, n.1, p.65-86.



showed the highest precision values (0.90 and 0.69, respectively), while the ROC curves and AUC scores demonstrated good generalization performance for these classes (0.84 and 0.79). Conversely, controlled burns exhibited lower predictive performance. SHAP (Shapley Additive Explanations) analyses revealed that variables such as biomass and unmonitored areas play a key role in modeling the classification of fire occurrences.

Keywords: Machine learning, Fire typification, Legal Amazon, Fire Panel.

1. 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 Amazônia 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 Manejo Integrado do Fogo (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 considerado 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 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; 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.


Espera-se 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.

2. Material e Métodos

2.1. 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).

Figura 1 - Eventos de fogo do Painel de fogo do CENSIPAM utilizados no cruzamento com as ocorrências de fogo do ICMBIo. Amazônia Legal (2023).



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 e 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).

2.2. Coleta e classificação de relatórios de ocorrências de incêndios ICMBIO

Foi coletado o relatório de ocorrências do fogo do ICMBio do ano 2023 e utilizado quatro parâmetros necessários para sua espacialização: coordenadas, data, tipo de queima e Unidade Federal, ou nome da Unidade de Conservação (UC) onde foi atendida a ocorrência (Tabela 1).

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 -17.96 Lon -43.73
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-8.72 Lon -54.56

Os dados dos relatórios do ICMBio e CBM que não apresentaram coordenadas geográficas foram excluídos do processo de mapeamento da informação.

2.3. 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 calor 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 não 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 (m ³ /ha)
biomass_ag	Biomassa aérea na área do evento (t/ha)
tree_cover	Cobertura de árvores (Km ²)
deter_area	Área desmatada (km ²) projeto DETER

Neste sentido, cada um dos rótulos é composto pelas variáveis *area_km2* e *persistenc*, que descrevem, respectivamente, a extensão espacial (maior que 1 ha) e a duração do evento de fogo (em dias). Já o atributo *qtd_detecc* representa o número de detecções de focos de calor durante o período em que o evento esteve ativo, conforme os registros da plataforma Painel do Fogo.

As variáveis ambientais foram obtidas a partir do GFED Amazon Dashboard, sendo o índice de cobertura de árvores (*tree_cover*) corresponde à fração média de cobertura arbórea dentro do polígono do evento de fogo. Para as variáveis de biomassa, foi utilizado o produto GlobBiomass (Santoro et al., 2018), que fornece as estimativas *biomass_gs*, referentes às árvores vivas com diâmetro à altura do peito superior a 10 cm, e *biomass_ag*, que contempla todas as árvores vivas, excluindo troncos e raízes (Dias, 2023).

Em relação às variáveis de ocupação da terra, tais como *a_terr_pri*, *a_terr_pub* e *a_terr_unk*, representam as áreas classificadas como privadas, públicas e sem classificação fundiária definida. Destaca-se que as áreas desconhecidas se referem às regiões sem enquadramento fundiário nas bases oficiais disponíveis. A variável *area_car* corresponde à área declarada no Cadastro Ambiental Rural (CAR).

Por outro lado, as áreas de terras indígenas (*a_terr_in*), unidades de conservação (*areakm2_uc*) e a área desmatada (*deter_area*), fornecida pelo mapa de alertas do Sistema de detecção do desmatamento em tempo real (DETER), também foram consideradas para cada polígono de evento de fogo, compondo o acervo de dados utilizado no cruzamento com as ocorrências reportadas pelo ICMBio.

2.3. Cruzamento de ocorrências do fogo e eventos do fogo do painel.

Uma vez espacializadas as ocorrências de fogo previamente verificadas 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 dos 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 >= dt_evento AND data_ocorrência <= 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.

2.4. Implementação e seleção dos modelos de aprendizado de máquina.

Após o cruzamento dos dados, foi necessário padronizar o conjunto de dados com o intuito de tornar as observações comparáveis e obter melhor desempenho nos resultados. O método mais comum é o Min-Max, que consiste em (Equação 01):

$$IA_{\text{padronizadoj}} = \frac{IA_j - IA_{\min}}{IA_{\max} - IA_{\min}} \quad (01)$$

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

Uma vez realizada 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 verificada a existência de outliers ou valores nulos que pudessem afetar o desempenho da generalização dos modelos. Foram utilizados os modelos Árvores 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, foi utilizado o método *Holdout Random Resampling* (Maillard et al., 2021), variando a composição de diferentes subconjuntos de treinamento e teste. Nesse sentido, foram realizadas 100 repetições para avaliar, em um primeiro momento, a estabilidade e a consistência de cada modelo em diferentes subconjuntos de treinamento e validação, mantendo os mesmos parâmetros do algoritmo de aprendizagem. Adicionalmente, foi utilizada a técnica *cross-validation* (Pérez et al., 2015), que consistiu em dividir o conjunto de dados em *k-fold*, garantindo que pelo menos uma vez cada uma das instâncias possa ser utilizada no treinamento, o que contribuiu para prevenir o sobreajuste dos modelos 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 Suport 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* 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; Zeybek, 2021).

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

Para determinar como cada variável influencia nas decisões dos modelos, foram utilizados os valores *Shapley Additive Explanations* (Lundberg; 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. Essa interpretação permite quais atributos do conjunto de dados são aparentemente mais relevantes para a tarefa de predição nos modelos de aprendizado de máquinas e como eles podem impactar nas decisões dos modelos na classificação dos tipos de eventos de fogo.

3. Resultados e Discussão

3.1. Espacialização de 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 (Figura 2).

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



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 foram o Parque Nacional do Pantanal Mato-Grossense (95), Estação Ecológica Serra Geral do Tocantins (80) e Reserva Extrativista Tapajós-Arapiuns (75) (Figura 2).

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).


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

Esse dado foi verificado por Mataveli et al., (2024), os quais 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.

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

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).

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


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 em 2023.

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

O impacto do uso do fogo nas UF's 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, prescrito e controlado). Os gráficos de linha mostram os padrões de alguns atributos dessa junção de dados 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).


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.



Esse tempo 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.

O cruzamento das queimas prescritas com os atributos dos eventos de fogo, evidenciou 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).


Figura 6 – (a) Média de perda de áreas nas UCs (*areakm²_uc*) nos eventos de fogo cruzadas 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.



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 controladas atingem cerca de 50 km², o que sugere que as práticas de gestão do fogo realizadas pelos brigadistas refletiram de maneira positiva dentro das UCs contribuindo para a redução da área afetada e, consequentemente, para uma menor perda de cobertura florestal.

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 cruzadas 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, consequentemente, favorecer a mitigação indireta das emissões de CO₂ associadas aos incêndios florestais.

Nesse sentido, Amapá (AP) e 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).

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.



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).

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

Uma vez realizadas essas análises, foi realizada 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).

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


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.

3.4.1. 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. Na figura 9, se mostra o desempenho dos modelos ao longo de 100 repetições com a técnica *Holdout*.

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



Como resultado, o modelo SVM (Figura 9a) apresentou a menor acurácia média (linha vermelha tracejada), em torno de 0,47, além de maior dispersão dos pontos azuis, que representam a acurácia obtida em cada repetição, variando entre 0,35 e 0,55. O modelo DT (Figura 9b) alcançou acurácia média de 0,58, com maior estabilidade em relação ao SVM. Por sua vez, o modelo RF apresentou os pontos mais concentrados próximos à média (0,63) e menor dispersão entre as repetições.

Essa interpretação pode ser corroborada pela Figura 10, na qual se evidencia que o modelo RF apresentou o melhor desempenho, além de menor desvio padrão em comparação aos modelos SVM e DT.

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

Ressalta-se que o RF e DT apresentaram desempenho superior ao valor de referência da acurácia média (0,5). Com tudo, esses resultados reforçam que o RF apresentou maior generalização para o conjunto de dados de teste, evidenciando maior capacidade preditiva na tipificação de fogo.

3.4.2. Validação cruzada

Nesta pesquisa, devido ao número limitado de observações obtidas a partir 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 5.

Tabela 5 – Otimização de parâmetros utilizados para a validação dos dados de teste.

Aprendizado de Máquina.	Hiperparâmetros	Acurácia Média	Desvio Padrão
<i>Vector Suport Machine</i> (SVM)	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</i> (DT)	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
	Random State = 42, max_depth= 16, n_estimators= 100,	0.603	0.035

<i>Random Forest</i> (RF)	min_samples_split= 8, max_features = 10		
	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 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. Uma vez realizado o procedimento anterior, foram realizadas generalizações no conjunto de dados de teste, ou seja, nos dados não vistos, obtendo-se os seguintes resultados (Tabela 6).

Tabela 6 – 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%			

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.

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).

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



Os valores de AUC para todas as classes variaram entre 0,80 e 0,90, o que demonstra que o modelo apresenta muito bom desempenho preditivo. Esse resultado segue critérios amplamente adotados na literatura, segundo autores como Chen et al., (2018) e Akinci e Zeybek, (2021), que consideram que valores de AUC superiores a 0,80 são indicativos de modelos com alto poder discriminativo, o que confirma que o modelo RF implementado neste trabalho, apresenta resultados confiáveis para realizar previsões na classificação dos diferentes tipos de fogo.


Já 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.

3.5. 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 nas demais categorias de queimadas, com fins de visualização dos resultados.

Note-se que na primeira previsão o modelo classificou corretamente o tipo de queimada (Figura 12 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.

Figura 12 – 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 - Tocantis, 30 de junho de 2023. (d-d1) Reserva Extrativista Chico Mendes, Epiaciolândia - 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.




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).

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. 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 associados consequentemente ao tamanho dos eventos, demandam, em geral, ações de combate mais intensivas.

3.6. Análise de importância de valores SHAP (Shapley Additive Explanations)

Na Figura 13a, observa-se que as variáveis *a_terr_pub*, *area_car*, *areakm2_uc* e *qtd_detec* apresentaram contribuições negativas. Esse comportamento indica que valores dessas variáveis reduzem a probabilidade de classificar determinadas tipologias de uso do fogo. No entanto, o modelo SVM apresentou baixa acurácia (0,59), o que indica que o resultado dessas contribuições aqui apresentado deve ser interpretado com cautela.

Figura 13 – (a) Gráfico de contribuições individuais de variáveis para o modelo SVM. (b) Gráfico de 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.



O modelo DT (Figura 13b), a variável *area_car* apresentou a maior contribuição negativa, indicando ser o atributo com maior influência na redução da probabilidade de determinadas classificações. Aqui o contexto fundiário teve maior relevância na distinção dos tipos de uso do fogo. Nesse sentido, o modelo considerou uma variável antropogênica como uma condição na distinção do tipo de fogo. Segundo Pivello (2011), o fogo antropogênico em propriedade privada altera significativamente os regimes naturais de fogo na Amazônia, sendo frequentemente associado ao uso vinculado a práticas de manejo agropecuário, como a renovação de pastagens e o manejo da vegetação (Morton et al., 2006). Com base nessa interpretação, este modelo

identificou essa condição para aumentar a capacidade de distinguir queimadas prescritas e controladas, mas, por outro lado, dificultou a capacidade de distinção da classe queima de combate, uma vez que o modelo atribuiu maior relevância à variável relacionada ao manejo antrópico para as previsões, em detrimento de atributos associados a incêndios não controlados.

Por outro lado, o RF (Figura 13c), identificou 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 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 são 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 conseguiram 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, amplamente discutidos 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 nos processos de modelagem, uma vez que ampliam a capacidade preditiva na distinção da tipificação do uso do fogo.

4. Conclusão

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. Portanto, 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 máquina 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 explorar outros modelos para aprimorar a classificação e aumentar a acurácia dos resultados.

Os valores SHAP mostraram que, quanto maior for 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, visto que foi possível identificar as áreas com maior número de eventos de fogo combatidos pelas brigadas, e 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. 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.

5. 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.

6. Referências

- Alencar, A., Moutinho, P., Arruda, V., & Silvério, D. (2020). Amazônia em chamas: o fogo e o desmatamento em 2019 e o que vem em 2020. Nota técnica, n. 3.
- Alencar, A., Martenexen, L., Gomes, J., Morton, D., & Brando, P. (2024). Amazônia em chamas: entendendo a relação entre o fogo e o desmatamento em 2023. Nota técnica, n. 12.
- Antunes, E. H., Ribeiro, V. R. S., Da Silva Nogueira, D. F., Cunha, P., Bernini, H., & De Faria, D. R. (2023, abril). Mapeamento de áreas espúrias para o Painel do Fogo. In XX Simpósio Brasileiro de Sensoriamento Remoto (SBSR), Florianópolis, Brasil.
- Aragão, L., Malhi, Y., Barbier, N., Lima, A., Shimabukuro, Y., Anderson, L., & Saatchi, S. (2008). Interactions between rainfall, deforestation and fires during recent years in the Brazilian Amazonia. **Philosophical Transactions of the Royal Society B: Biological Sciences**, 363, 1779-1785.
- Aragão, L. E., Poulter, B., Barlow, J., 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., Akinci, H., & Zeybek, M. (2024). Comparison of diverse machine learning algorithms for forest fire susceptibility mapping in Antalya, Türkiye. **Advances in Space Research**.
- Akinci, H., & Zeybek, M. (2021). Comparing classical statistic and machine learning models in landslide susceptibility mapping in Ardanuc (Artvin), Turkey. **Natural Hazards**, 108, 1515-1543.
- Breiman, L. (2001). Random forests. **Machine Learning**, 45, 5-32.

Barlow, J., Berenguer, E., Carmenta, R., & França, F. (2020). Clarifying Amazonia's burning crisis. **Global Change Biology**, 26, 319-321.

CENSIPAM - Centro Gestor e Operacional do Sistema de Proteção da Amazônia. Painel do Fogo. 2025. Disponível em: <https://panorama.sipam.gov.br/painel-do-fogo/>. Acesso em: 20 maio 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**, 626, 1121-1135.

Conselho Nacional do Meio Ambiente. (1988). Resolução CONAMA nº 11. Diário Oficial da União, Brasília, DF, 14 dez. 1988.

Conselho Nacional de Justiça. (2024). Crimes ambientais na Amazônia Legal: a atuação da justiça nas cadeias de lavagem de bens e capitais, corrupção e organização criminosa. 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 França, R., & Laranja, R. (2021). Implementation of fire policies in Brazil: an assessment of fire dynamics in Brazilian savanna. **Sustainability**, 13, 11532.

Dias, B. S. S. (2023) **Tipificação de incêndios florestais na Amazônia Legal através de aprendizado de máquina**. 2023. Trabalho Final de Graduação (Engenharia de Redes de Comunicação). Faculdade de Tecnologia, Universidade de Brasília, Brasília.

Dias, F., Suhadolnik, N., Camargo, H., & Da Silva, S. (2024). Predicting the pulse of the Amazon: machine learning insights into deforestation dynamics. **Journal of Environmental Management**, 362, 121359.

Dong, H., Wu, H., Sun, P., & Ding, Y. (2022). Wildfire prediction model based on spatial and temporal characteristics: a case study of a wildfire in Portugal Montesinho Natural Park. **Sustainability**, 14, 10107.

Domínguez, D., Del Villar, P., Pantoja, O., & González, M. (2022). Forecasting Amazon rainforest deforestation using a hybrid machine learning model. **Sustainability**, 14, 691.

Fávero, L., & Fávero, P. (2017). **Análise de dados: técnicas multivariadas exploratórias com SPSS e STATA**. Rio de Janeiro: Elsevier Brasil.

Ferro, P., De Medeiros, T., Dutra, D., Mataveli, G., Anderson, L., Pessoa, C., & De Souza, C. (2023). **Deteção de áreas queimadas baseada no modelo linear de mistura espectral aplicado a cubos de dados CBERS-4 e CBERS-4A no oeste de Rondônia, Brasil**. Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil.

Hair, J. F. (2009). **Análise multivariada de dados**. Porto Alegre: Bookman.

Herrmann, P., Nascimento, V., Casagrande, F., & De Freitas, W. (2023). 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**, 131, 104614.

- Homma, A. K. O. (2020). **Amazônia: a civilização do fogo. In Da tradição das queimadas à agricultura sustentável na Amazônia.** Embrapa.
- IcmBio – Instituto Chico Mendes de Conservação da Biodiversidade. (2022). Portaria ICMBio nº 1.150, de dezembro de 2022. Diário Oficial da União, Brasília, DF.
- Kavzoglu, T., & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. **International Journal of Applied Earth Observation and Geoinformation**, 11, 352-359.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model prediction. In Proceedings of the 31st Conference on Neural Information Processing Systems (NeurIPS).
- Maillard, G., Arlot, S., & Lerasle, M. (2021). Aggregated hold-out. **Journal of Machine Learning Research**, 22(20), 1-55.
- Mataveli, G., Jones, M. W., Carmenta, R., Sanchez, A., Dutra, D., Chaves, M., & Aragão, L. (2024). Deforestation falls but rise of wildfires continues degrading Brazilian Amazon forests. **Global Change Biology**, 30, 17202.
- 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. (2024). Spatialization of fire occurrences in Brazil within the context of the fire events detected by the fire panel. **RA'E GA - O Espaço Geográfico em Análise**, 60, 131-158.
- Morton, D. C., DeFries, R. S., Shimabukuro, Y. E., Anderson, L. O., Arai, E., Bon Espirito Santo, F., & Morisette, J. (2006). Cropland expansion changes deforestation dynamics in the southern Brazilian Amazon. **Proceedings of the National Academy of Sciences**, 103(39), 14637-14641.
- Pang, Y., Li, Y., Feng, Z., Zhao, Z., Chen, S., & Zhang, H. (2022). Forest fire occurrence prediction in China based on machine learning methods. **Remote Sensing**, 14, 5546.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., & Duchesnay, É. (2011). Scikit-learn: machine learning in Python. **Journal of Machine Learning Research**, 12, 2825-2830.
- Pivello, V. R. (2011). The use of fire in the Cerrado and Amazonian rainforests of Brazil: past and present. **Fire ecology**, 7(1), 24-39.
- Reddington, C. L., Butt, E. W., Ridley, D. A., Artaxo, P., Morgan, W. T., Coe, H., & Spracklen, D. V. (2015). Air quality and human health improvements from reductions in deforestation-related fire in Brazil. **Nature Geoscience**, 8, 768-771.
- Rocha, S., & Rauber, L. (2023). Amazônia Legal Brasileira: incidência de focos de calor entre 2001 e 2020 e sua correlação com o desmatamento de corte raso. **Revista Equador**, 12, 199-226.

Santoro, M., Cartus, O., Mermoz, S., Bouvet, A., Le Toan, T., Carvalhais, N., et al. (2018). **GlobBiomass global above ground biomass and growing stock volume datasets**. <http://globbiomass.org/products/global-mapping/>

Sun, Y., Lin, H., & Xu, S. (2022). Forest fire susceptibility modeling approach based on the Light Gradient Boosting Machine algorithm. **Remote Sensing**, 14, 4362.

Xu, W., Liu, Y., Veraverbeke, S., Wu, W., Dong, Y., & Lu, W. (2021). Active fire dynamics in the Amazon: new perspectives from high-resolution satellite observations. **Geophysical Research Letters**, 48.

Zhang, G., Wang, M., & Liu, K. (2021). Deep neural networks for global wildfire susceptibility modelling. **Ecological Indicators**, 127, 107735.