

MODELO DE PREDIÇÃO DE INCÊNDIOS FLORESTAIS UTILIZANDO REML/BLUP: UMA PROPOSTA ABRANGENTE PARA A AMAZÔNIA LEGAL E IMPLICAÇÕES PARA PREVENÇÃO E JUSTIÇA

Trabalho de Avaliação e Perícia Ambiental

SANDRO SPONCHIADO
FRANCO PERAZZONI
MAURO MENDONÇA MAGLIANO

João Pessoa - PB
2025

REALIZAÇÃO:



PATROCÍNIO:



MODELO DE PREDIÇÃO DE INCÊNDIOS FLORESTAIS UTILIZANDO REML/BLUP: UMA PROPOSTA ABRANGENTE PARA A AMAZÔNIA LEGAL E IMPLICAÇÕES PARA PREVENÇÃO E JUSTIÇA

RESUMO

A Amazônia Legal é uma região vital para o equilíbrio climático global e a preservação da biodiversidade, mas enfrenta ameaças crescentes devido à intensificação dos incêndios florestais. Este estudo propõe um modelo preditivo funcional para qualificar focos de incêndio, com o objetivo de melhorar a prevenção e permitir a responsabilização de ações criminosas. A metodologia integra dados meteorológicos do INMET e informações sobre queimadas do BDQUEIMADAS (INPE), utilizando o método REML/BLUP para estimar com precisão os focos de calor. Técnicas de Inteligência Artificial, como Random Forest, são aplicadas para identificar variáveis relevantes e relações não lineares entre os dados. Apesar dos desafios na correlação e interpolação das informações, os resultados iniciais indicam que a combinação dessas bases é viável. O uso de dados de estações meteorológicas de municípios vizinhos contribuiu para melhorar as estimativas. A seleção de focos de calor precursores foi possível por meio da análise de padrões de redução de raio de observação em dias subsequentes. O modelo se mostra promissor tanto para ações preventivas quanto para fortalecer a perícia e a justiça ambiental, protegendo os ecossistemas e as populações locais da Amazônia.

Palavras-chave: *REML/BLUP; Prevenção de incêndios; Modelagem preditiva; Amazônia legal; Sensoriamento remoto*

REALIZAÇÃO:



PATROCÍNIO:



SUMÁRIO

1. INTRODUÇÃO	4
1.1. Amazônia: Importância Ecológica e Ameaças dos Incêndios Florestais ...	4
1.2. A Urgência de Desenvolvimento de Modelos Preditivos Funcionais	4
1.3. Objetivos do Estudo e Contribuições para a Ciência e a Sociedade	5
2. REVISÃO DA LITERATURA	6
2.1. Causas e Dinâmicas dos Incêndios Florestais na Amazônia	6
2.2. Modelagem Preditiva de Incêndios Florestais: Abordagens e Avanços	6
2.3. O Método REML/BLUP em Modelagem Espacial e Ambiental	7
2.4. Random Forest para Seleção de Variáveis e Relações Não Lineares	7
3. METODOLOGIA	8
3.1. Integração e Fontes de Dados	8
3.2. Formulação do Modelo Preditivo	9
3.3. Avaliação da Resolução do Modelo: O Método REML/BLUP	11
3.4. Otimização de Parâmetros Espaciais e Temporais	11
4. RESULTADOS E DISCUSSÃO	12
5. IMPLICAÇÕES E APLICAÇÕES	13
5.1. Prevenção Ativa de Incêndios Florestais	13
5.2. Auxílio na Identificação de Responsáveis por Incêndios Criminosos	13
6. CONCLUSÃO	14
REFERÊNCIAS	14

REALIZAÇÃO:



PATROCÍNIO:



1. INTRODUÇÃO

1.1. Amazônia: Importância Ecológica e Ameaças dos Incêndios Florestais

A Amazônia Legal ocupa grande parte do território brasileiro e é fundamental para o equilíbrio ecológico, a regulação do clima e a preservação da biodiversidade. Sua floresta desempenha papel essencial no ciclo hidrológico e climático da América do Sul, com efeitos que alcançam até outros continentes, influenciando padrões de chuva e condições ambientais globais.

A integridade dos biomas amazônicos, no entanto, está cada vez mais ameaçada pelo aumento dos incêndios florestais, que são em grande parte resultado de atividades humanas. O desmatamento e a expansão da agropecuária são as principais causas desses incêndios, especialmente por meio de práticas como a queimada para limpar áreas e o uso do fogo no manejo de pastagens, o que torna a floresta mais vulnerável ao fogo (Aragão e Shimabukuro 2010).

Os impactos desses incêndios são severos e afetam diversos aspectos. A destruição das florestas compromete a economia regional, ameaça a sustentabilidade dos recursos naturais e expõe a população a riscos à saúde, como doenças respiratórias e cardiovasculares causadas pela inalação de fumaça e poluentes (HRW et al. 2020).

Além disso, a perda de cobertura florestal alimenta um ciclo de degradação ambiental: os incêndios e o desmatamento alteram o clima local e criam condições que facilitam novos focos de fogo. Essa dinâmica tem repercussões além da região amazônica, afetando o regime de chuvas e a segurança alimentar em outras partes do continente, e representa uma crise de dimensões globais que desafia a sustentabilidade e o equilíbrio ambiental (Bowman et al. 2009).

1.2. A Urgência de Desenvolvimento de Modelos Preditivos Funcionais

Diante da ameaça crescente e multifacetada imposta pelos incêndios na Amazônia, o desenvolvimento de modelos preditivos funcionais para qualificar focos de incêndio torna-se um imperativo. A complexidade de prever com precisão quando e onde ocorrerão grandes incêndios florestais é uma tarefa desafiadora, mas fundamental para o planejamento eficaz de ações de pronta resposta e para a minimização de danos.

Modelos preditivos são componentes essenciais de Sistemas de Suporte à Decisão (DSS), que representam ferramentas poderosas para prevenir e gerenciar incêndios florestais, otimizando o uso eficiente de recursos. Esses sistemas permitem a alocação preventiva de recursos para áreas identificadas como de alto risco, antecipando a ocorrência de focos e permitindo uma resposta mais rápida e eficaz (Jain et al. 2020).

Apesar dos avanços tecnológicos e metodológicos, a previsão de futuros incêndios ainda é limitada pela falta de uma compreensão completa dos fatores que desencadeiam e controlam a dinâmica desses eventos. Além disso, a dificuldade em distinguir incêndios florestais reais de vários tipos de alarmes falsos, gerados por outras fontes de calor ou anomalias, representa um desafio significativo para a acurácia e a eficácia dos sistemas de monitoramento (Jain et al., 2020).

Em outras palavras, a necessidade de modelos preditivos vai além da mera previsão de ocorrência; ela se estende à alocação preventiva de recursos e à otimização da pronta resposta. Isso transforma a previsão de um exercício acadêmico em uma ferramenta de gestão proativa de crises, onde a capacidade de identificar focos com alta probabilidade de se tornarem grandes incêndios é um diferencial estratégico para minimizar danos e custos de supressão. A precisão e a granularidade do modelo podem ter um impacto direto na redução de danos e custos de supressão, ao permitir que as equipes ajam antes que os incêndios se tornem incontrolláveis, otimizando o uso de recursos escassos e contribuindo para uma resposta mais eficiente.

Apesar da sofisticação dos modelos, a persistente lacuna na compreensão do que desencadeia e controla a dinâmica dos incêndios, bem como a dificuldade em excluir falsos focos de incêndio, representam desafios significativos. Isso aponta para a necessidade crítica de dados de validação robustos e de verificação em campo para garantir que os modelos não apenas prevejam, mas também forneçam informações confiáveis para a responsabilização criminal. Para que os dados do modelo sirvam a propósitos legais, eles precisam ser robustos e defensáveis em um tribunal. Isso exige não apenas alta acurácia preditiva, mas também rastreabilidade, interpretabilidade e validade jurídica dos dados gerados, o que é um requisito muito mais rigoroso do que a simples previsão para fins de alocação de recursos. Este cenário estabelece uma ponte essencial entre a modelagem ambiental e a perícia forense.

1.3. Objetivos do Estudo e Contribuições para a Ciência e a Sociedade

O objetivo central deste estudo é o desenvolvimento de um modelo preditivo de focos relevantes de incêndio especificamente adaptado para os biomas da Amazônia Legal. A avaliação da resolução e da robustez deste modelo será realizada por meio do método REML/BLUP, reconhecido por sua capacidade de lidar com dados complexos e reduzir vieses (Resende 2002) (Piepho et al. 2008).

A contribuição deste modelo é multifacetada e de grande relevância. Primeiramente, ele visa apoiar a prevenção ativa de incêndios, fornecendo ferramentas para antecipar a ocorrência de incêndios e direcionar recursos de forma eficiente. Em segundo lugar, e de forma crucial, o modelo busca auxiliar na identificação dos responsáveis por incêndios de origem criminosa. Esta faceta é particularmente importante para a aplicação da Justiça, contribuindo para a proteção da biodiversidade e das comunidades locais, e para desincentivar a prática de crimes ambientais.

O estudo busca preencher lacunas significativas no conhecimento existente sobre os impactos do fogo em diversos serviços ecossistêmicos e bens, especialmente no que tange às perdas econômicas associadas à produção sustentável de madeira na região (Soares-Filho et al. 2017). Ao quantificar esses impactos, o modelo pode fornecer uma base para políticas públicas mais eficazes.

A capacidade de um modelo preditivo de incêndios florestais em apoiar a prevenção ativa e, simultaneamente, auxiliar na identificação de responsáveis por incêndios criminosos, transcende a mera gestão ambiental, elevando-o a uma ferramenta de governança ambiental e segurança jurídica. A precisão das previsões e a robustez dos dados gerados pelo modelo podem ser cruciais para a aplicação da justiça, fornecendo evidências para a responsabilização legal. Isso não apenas

fortalece a capacidade do Estado de combater a impunidade, mas também estabelece um precedente para o uso de tecnologias avançadas na persecução de crimes ambientais. A integração da previsão de incêndios com a inteligência forense pode, assim, criar um sistema mais eficaz para a proteção da Amazônia, promovendo a sustentabilidade e a equidade na região.

2. REVISÃO DA LITERATURA

2.1. Causas e Dinâmicas dos Incêndios Florestais na Amazônia

Os incêndios florestais na Amazônia são resultado da combinação de fatores naturais e, principalmente, de ações humanas. Embora raios e períodos de seca possam iniciar focos de fogo, o desmatamento, o uso do fogo no manejo de pastagens e atividades ilegais são as principais causas, ampliando a vulnerabilidade da região.

Fatores meteorológicos, como altas temperaturas, baixa umidade, ventos fortes e a falta de chuva, criam condições que favorecem a ignição e a propagação do fogo. Com as mudanças climáticas, esses fatores tendem a se intensificar, aumentando o risco de incêndios ao longo de todo o ano.

Além dos fatores ambientais, questões socioeconômicas, como falta de alternativas econômicas ao modelo de uso da terra, desigualdade e baixa escolaridade, também contribuem para o problema. A degradação causada pelos incêndios altera o clima local e reforça o ciclo de destruição, tornando essencial a adoção de estratégias integradas de prevenção que considerem aspectos ambientais, climáticos e sociais.

2.2. Modelagem Preditiva de Incêndios Florestais: Abordagens e Avanços

A modelagem preditiva de incêndios florestais passou por avanços importantes, incorporando soluções que unem métodos estatísticos e técnicas de aprendizado de máquina (ML). Enquanto os modelos estatísticos convencionais enfrentam dificuldades para representar a complexidade e as relações não lineares típicas dos incêndios em grande escala, algoritmos de ML — como Random Forest, SVM e redes neurais — se destacam por captar interações complexas entre variáveis como clima, relevo e uso do solo. Pesquisas recentes indicam que modelos como CatBoost e AutoGluon podem alcançar taxas de acurácia superiores a 90% nas previsões (Belgiu e Drăguț 2016).

O sensoriamento remoto tornou-se um recurso indispensável nesse contexto. Ferramentas como o MODIS permitem o acompanhamento quase em tempo real dos focos de calor, enquanto índices como NDVI e EVI auxiliam na estimativa da densidade e umidade da vegetação. Regiões com vegetação mais densa e úmida tendem a ser menos vulneráveis ao fogo, ao contrário de áreas com acúmulo de biomassa seca, que favorecem a ignição e a propagação das chamas. Dados coletados em diferentes momentos e índices espectrais complementam essas análises ao apontar áreas de maior risco e possibilitar a antecipação de novos focos (Zeng et al. 2022).

Apesar do progresso, alguns obstáculos permanecem, como o desbalanceamento dos dados — já que grandes incêndios representam uma pequena fração do total — e a identificação equivocada de focos de calor pelos sensores. Para lidar com esses problemas, utilizam-se técnicas como SMOTE e ADASYN para

balanceamento dos dados e métodos mais refinados para reduzir alarmes falsos. O sucesso da modelagem preditiva depende da solidez dos algoritmos e da articulação entre diferentes fontes de dados em sistemas de apoio à decisão, garantindo previsões seguras para orientar ações preventivas e respostas rápidas.

2.3. O Método REML/BLUP em Modelagem Espacial e Ambiental

O método REML/BLUP, que combina o *Restricted Maximum Likelihood* e o *Best Linear Unbiased Prediction*, é uma ferramenta estatística amplamente empregada em ensaios multiambientais, especialmente na análise de melhoramento genético. Ele permite estimar componentes de variância e prever valores genotípicos com alta precisão, eliminando o viés causado pelos efeitos do ambiente. Entre seus principais diferenciais está a capacidade de lidar com dados desbalanceados e corrigir tendências espaciais, aumentando a acurácia das previsões. O método permite ajustar modelos como o autorregressivo AR1 $\otimes$ AR1, que considera a dependência entre erros correlacionados e aleatórios, além de incorporar informações espaciais, como linhas e colunas, para refinar as análises (Rezende, 2002; Rezende, 2007).

Estudos apontam que o uso do REML/BLUP com ajustes espaciais proporciona maior acurácia seletiva, maior herdabilidade e ganho de seleção do que modelos que não consideram o componente espacial. Isso demonstra sua eficácia em reduzir erros de seleção e em modelar de forma mais realista os efeitos ambientais presentes nos ensaios (Piepho et al. 2008) (Resende 2002).

Embora o método seja amplamente aplicado na agricultura, seus princípios de modelagem robusta e correção de efeitos espaciais podem inspirar abordagens em contextos ambientais mais amplos. Sua capacidade de quantificar a variabilidade entre fatores genéticos e ambientais é essencial para o desenvolvimento de modelos preditivos confiáveis, que possam servir de base para decisões mais seguras e eficazes.

2.4. Random Forest para Seleção de Variáveis e Relações Não Lineares

O algoritmo Random Forest (RF) é uma técnica de aprendizado de máquina baseada em árvores de decisão, amplamente utilizada para seleção de variáveis e modelagem de relações não lineares. Sua aplicação neste estudo visa identificar os fatores mais relevantes para a ocorrência de incêndios florestais na Amazônia Legal, considerando a complexidade e a heterogeneidade dos dados ambientais e antrópicos. O RF é particularmente eficaz em contextos com grande número de variáveis correlacionadas, presença de dados ausentes e interações de alta ordem, características comuns em bases de dados ambientais.

Ao construir múltiplas árvores de decisão e combinar seus resultados, o RF reduz o risco de *overfitting* e melhora a generalização do modelo. A importância de cada variável é avaliada com base na redução da impureza média ou na perda de acurácia quando a variável é permutada. Essa abordagem permite identificar variáveis-chave, como temperatura, umidade, NDVI e uso do solo, que influenciam diretamente a ignição e propagação do fogo.

Além disso, o RF pode ser utilizado para gerar variáveis derivadas ou para alimentar modelos estatísticos mais interpretáveis, como o REML/BLUP. Essa integração entre métodos estatísticos e de inteligência artificial fortalece a capacidade preditiva e explicativa do modelo proposto.

3. METODOLOGIA

O desenvolvimento de um modelo preditivo de incêndios florestais para a Amazônia Legal requer uma metodologia robusta que integre diversas fontes de dados e empregue técnicas estatísticas e de aprendizado de máquina avançadas.

3.1. Integração e Fontes de Dados

O modelo de predição de incêndios integra dados meteorológicos e de queimadas, provenientes de fontes oficiais e reconhecidas.

Dados Meteorológicos (INMET):

- Dados meteorológicos, como pressão atmosférica, temperatura média, umidade relativa e velocidade do vento, são obtidos do Instituto Nacional de Meteorologia (INMET), uma fonte confiável de informações climáticas no Brasil, operando uma rede nacional de estações meteorológicas automáticas que coletam dados em tempo real e históricos.
- Esses parâmetros são registrados como médias diárias e servem como variáveis independentes em análises de regressão. A análise da influência desses parâmetros meteorológicos na distribuição de material particulado, por exemplo, é fundamental para identificar os principais impulsionadores e entender a complexa relação entre condições atmosféricas e a dinâmica de poluentes. A utilização de dados de estações meteorológicas de municípios vizinhos também se mostrou eficiente na melhoria das estimativas para áreas com dados ausentes.

Dados de Queimadas e Desmatamento (BDQUEIMADAS/INPE):

- Informações sobre queimadas e desmatamento são provenientes de bancos de dados como o BDQUEIMADAS do Instituto Nacional de Pesquisas Espaciais (INPE). O INPE utiliza o sensor MODIS a bordo do satélite Aqua como referência para monitorar a dinâmica espacial e temporal dos incêndios no Brasil, medindo o número de focos de calor ativos (Giglio et al., [s.d.]). Esses dados são considerados um indicador confiável das tendências de atividade de incêndio ao longo do tempo e são cruciais para estudos de impacto na saúde, pois capturam a dinâmica dos incêndios.
- Os dados de desmatamento são baseados no DETER-B, que representa alertas periódicos de desmatamento, agregados mensalmente. O DETER-B oferece uma resolução espacial aprimorada (de 250m para 60m) e inclui diversas classes de distúrbios na vegetação nativa, como mineração, extração de madeira, degradação florestal por fogo e desmatamento por corte raso (Almeida et al. 2016).

Dados de Cobertura Vegetal (NDVI e Projeto RADAM):

- A cobertura vegetal é uma variável crítica para a predição de incêndios, sendo estimada utilizando o *Normalized Difference Vegetation Index* (NDVI). O NDVI é calculado a partir da reflectância nas bandas do

infravermelho próximo (NIR) e vermelho (RED) do espectro eletromagnético, com valores que variam de -1 a +1, onde valores mais altos indicam maior conteúdo de clorofila e maior área foliar (Yengoh et al. 2014) (METER 2023).

- O NDVI é amplamente utilizado para estimar o Índice de Área Foliar (IAF) e a interceptação de luz, sendo um *proxy* para a capacidade fotossintética e a produção primária (Yengoh et al. 2014). Embora o NDVI possa saturar em valores de IAF muito altos, sua relação com a interceptação fracionária de luz (fPAR) geralmente não satura, tornando-o valioso para avaliar a quantidade de biomassa combustível (METER 2023).
- A validação da estimativa da cobertura vegetal por NDVI é realizada com dados de volumetria do Projeto RADAM. O Projeto RADAMBRASIL, iniciado na década de 1970, utilizou tecnologia pioneira de radar aerotransportado (SLAR) para mapear vastas extensões do território brasileiro, incluindo a Amazônia, independentemente da luz solar ou cobertura de nuvens (IBGE 2018). Este projeto monumental gerou uma vasta quantidade de informações sobre geologia, solos, vegetação, relevo e uso da terra, fornecendo a primeira visão integrada da paisagem amazônica (IBGE 2018). A validação com dados do RADAM garante a precisão da variável de cobertura vegetal, essencial para a acurácia do modelo preditivo.

A integração de dados multiescalares é essencial para a construção de modelos preditivos robustos de incêndios. A combinação de informações meteorológicas do INMET, dados de focos de calor e desmatamento do INPE e índices de vegetação como o NDVI, validados por levantamentos históricos como o Projeto RADAM, oferece uma visão ampla e detalhada das condições que favorecem os incêndios.

Os desafios na correlação e interpolação desses dados heterogêneos são superados com o uso de técnicas estatísticas e de inteligência artificial, que transformam essas informações em uma base integrada e consistente. Essa estrutura complexa, porém, coesa, permite ao modelo capturar com maior precisão a dinâmica do fogo e suas interações com o ambiente, resultando em previsões mais confiáveis e alinhadas ao contexto real.

3.2. Formulação do Modelo Preditivo

O modelo de predição de focos de incêndio é formulado para integrar dados de diversas fontes, utilizando uma abordagem que considera coordenadas geográficas, termos de erro e efeitos aleatórios para regiões específicas.

A equação geral do modelo é expressa da seguinte forma:

$$Y = \beta_0 + \beta_1 \cdot x(t) + \beta_2 \cdot y(t) + \beta_3 \cdot T(t) + \beta_4 \cdot U(t) + \beta_5 \cdot V(t) + \beta_6 \cdot H(t) + \beta_7 \cdot C(t) + \delta_{x, \text{região}} + \delta_{y, \text{região}} + \varepsilon_x + \varepsilon_y$$

Onde:

- $x(t)$ e $y(t)$ são as coordenadas (longitude e latitude) do local de início do incêndio.
- $T(t)$ é a temperatura média.
- $U(t)$ é a umidade relativa.
- $V(t)$ é a cobertura vegetal.
- $H(t)$ é o histórico de incêndios.
- $C(t)$ é o tipo de uso do solo.
- β_0 a β_7 são os coeficientes dos efeitos fixos, representando a contribuição média de cada variável para a probabilidade de incêndio.
- $\delta x, \text{região}$ e $\delta y, \text{região}$ são os efeitos aleatórios para cada região específica, capturando a variabilidade não explicada pelas variáveis fixas e que pode ser atribuída a características intrínsecas de cada região.
- ϵ_x e ϵ_y são os termos de erro, representando a variabilidade residual não capturada pelo modelo.

As variáveis incorporadas no modelo foram selecionadas com base em sua relevância para a ocorrência e propagação de incêndios florestais. Além das coordenadas geográficas, temperatura, umidade relativa, cobertura vegetal, histórico de incêndios e tipo de uso do solo, variáveis adicionais poderão ser incorporadas, seja para uso direto no modelo ou para gerar dados para variáveis com dados ausentes ou que necessitam ser estimado. A temperatura e a umidade são fatores meteorológicos cruciais que influenciam diretamente o comportamento do fogo e o potencial de ignição. A cobertura vegetal, estimada por NDVI, é um indicador da quantidade e tipo de combustível disponível (Yengoh et al. 2014). O histórico de incêndios reflete a suscetibilidade de uma área a eventos recorrentes, enquanto o tipo de uso do solo (por exemplo, floresta, pastagem, agricultura) está fortemente ligado às causas antrópicas e à gestão da terra (Almeida et al. 2016).

Para a estimativa de dados faltantes (colunas com número de linhas diferentes/sem dados), foram utilizadas técnicas de correlação e interpolação. Além disso, métodos quantitativos como regressão linear e Random Forest, bem como técnicas de Inteligência Artificial, foram empregados para identificar as variáveis mais significativas e as relações não lineares entre elas. O Random Forest, em particular, é eficaz em detectar relações complexas e interações de alta ordem entre variáveis, além de lidar com dados ausentes e *outliers* (Yengoh et al. 2014).

A arquitetura do modelo é projetada para capturar a dinâmica complexa dos incêndios florestais na Amazônia. A inclusão de efeitos fixos para variáveis ambientais e socioeconômicas, combinada com efeitos aleatórios para regiões específicas, permite que o modelo se adapte à heterogeneidade espacial e temporal do fenômeno. Esta abordagem, que integra o conhecimento de múltiplos fatores de risco, é fundamental para que o modelo não apenas preveja a ocorrência de incêndios, mas também forneça uma compreensão mais profunda dos mecanismos subjacentes. A capacidade de incorporar variáveis adicionais e de tratar dados ausentes por meio de técnicas avançadas garante a flexibilidade e a adaptabilidade do modelo a diferentes cenários e à evolução dos dados disponíveis.

3.3. Avaliação da Resolução do Modelo: O Método REML/BLUP

A resolução do modelo está sendo testada com o método REML/BLUP (Restricted Maximum Likelihood / Best Linear Unbiased Prediction), que é reconhecido por sua capacidade de reduzir ruídos e viés nos dados. Este método é fundamental para garantir a acurácia e a confiabilidade das previsões do modelo, especialmente em contextos em que os dados podem ser desbalanceados ou apresentar tendências espaciais (Piepho et al. 2008) (Resende_1 2007).

A aplicação do REML/BLUP permite a estimação de componentes de variância e a previsão de valores genotípicos ou, neste caso, de valores preditivos, de forma mais precisa e imparcial, minimizando a influência de efeitos ambientais não controlados. Em ensaios multiambientais, como a análise de focos de incêndio em diferentes regiões da Amazônia, o REML/BLUP é capaz de modelar diferentes estruturas de resíduos e covariância, o que é crucial para lidar com a heterogeneidade inerente aos dados. Para corrigir tendências espaciais, uma estrutura de modelo autorregressivo de primeira ordem ($AR1 \otimes AR1$) pode ser empregada, que considera um erro correlacionado e um erro aleatório independente, aumentando a acurácia seletiva (Resende e Sturion 2001).

A principal vantagem do REML/BLUP é sua capacidade de reduzir ruídos e vieses nos dados. Ao estimar os componentes de variância de forma restrita, o REML produz estimativas menos enviesadas, especialmente em amostras pequenas ou desbalanceadas. O BLUP, por sua vez, utiliza essas estimativas para prever os efeitos aleatórios, resultando em previsões mais acuradas e imparciais. A inclusão de efeitos aleatórios para regiões específicas, como $\delta x, \text{região}$ e $\delta y, \text{região}$ na equação, permite que o modelo capture a variabilidade não explicada pelas variáveis fixas e que é inerente a cada localidade, aprimorando a precisão das previsões para áreas específicas. A diminuição da variância residual dentro dos ensaios, resultante da modelagem de resíduos que considera a dependência entre linhas e/ou colunas, maximiza a acurácia seletiva nos ambientes (Piepho et al. 2008) (Resende_1 2007).

A validação com REML/BLUP é fundamental para garantir a robustez estatística do modelo, reduzindo ruídos e vieses e aumentando a confiabilidade das previsões. Essa precisão é crucial tanto para sistemas de alerta precoce quanto para embasar processos de responsabilização criminal. Além disso, a capacidade do método em lidar com a complexidade dos dados geoespaciais e temporais, ao modelar efeitos fixos e aleatórios, torna o modelo não só preditivo, mas também cientificamente sólido (Olafsson et al. 2025). Isso assegura uma base consistente para a tomada de decisões e o fortalecimento da justiça ambiental.

3.4. Otimização de Parâmetros Espaciais e Temporais

A validação do modelo preditivo de incêndios indica que ajustes no comprimento do raio e no período de observação são fundamentais para aprimorar a detecção de focos iniciais. A definição adequada desses parâmetros espaciais e temporais é essencial para o funcionamento eficaz do sistema de monitoramento e alerta, garantindo que as previsões sejam mais precisas e as respostas mais ágeis.

No caso do raio de detecção, um valor muito amplo pode gerar falsos positivos e sobrecarregar os recursos de resposta, enquanto um raio muito restrito pode atrasar a identificação de focos reais, comprometendo o combate ao fogo. De modo semelhante, o período de observação precisa ser calibrado para identificar a dinâmica

dos focos de calor ao longo do tempo, considerando sua persistência e evolução. Isso demanda o uso de séries temporais e dados multitemporais para identificar anomalias e padrões que precedem os incêndios.

Por fim, a eficácia operacional do modelo depende de uma calibração contínua desses parâmetros, com ajustes baseados em *feedback* de campo para reduzir falsos alarmes e melhorar a capacidade de resposta. Essa otimização transforma o modelo de previsão em uma ferramenta prática de gestão de crises, garantindo que os dados gerados apoiem de forma real a intervenção rápida e eficiente das equipes de combate (Zhalehdoost e Taleai 2025).

4. RESULTADOS E DISCUSSÃO

Até o momento, o modelo preditivo de incêndios florestais proposto encontra-se em fase de desenvolvimento e calibração. A estrutura conceitual foi definida com base na integração de dados meteorológicos, de cobertura vegetal e de histórico de queimadas, utilizando o método REML/BLUP para estimativas robustas e imparciais, mesmo em cenários com dados desbalanceados. Paralelamente, técnicas de aprendizado de máquina, como Random Forest, estão sendo testadas para seleção de variáveis e identificação de padrões não lineares.

Os testes iniciais de consistência dos dados revelaram desafios importantes relacionados à heterogeneidade das fontes. Em particular, a interpolação de dados meteorológicos de estações com cobertura irregular exigiu o uso de métodos estatísticos complementares, como regressão múltipla e krigagem, para preencher lacunas e garantir a continuidade das séries temporais. A validação cruzada desses dados está em andamento, com foco na minimização de erros sistemáticos.

A estrutura do modelo incorpora variáveis como temperatura média, umidade relativa, tipo de uso do solo, cobertura vegetal (via NDVI), histórico de incêndios e localização geográfica. A equação geral foi formulada para permitir a inclusão de efeitos aleatórios por região, o que é essencial para capturar a variabilidade espacial não explicada por fatores fixos. Essa abordagem é especialmente relevante na Amazônia Legal, onde as condições ambientais e socioeconômicas variam significativamente entre os municípios.

Embora os resultados quantitativos ainda não estejam disponíveis, análises exploratórias indicam que a combinação de NDVI com dados de desmatamento do DETER-B pode ser um bom preditor da suscetibilidade ao fogo. Áreas com baixa densidade de vegetação e histórico recente de queimadas tendem a apresentar maior frequência de focos de calor, o que reforça a importância de variáveis derivadas de sensoriamento remoto.

Além disso, a modelagem está sendo ajustada para testar diferentes janelas temporais e raios de detecção, com o objetivo de identificar os parâmetros mais eficazes para antecipar focos de incêndio com antecedência operacionalmente útil. A expectativa é que, uma vez calibrado, o modelo seja capaz de gerar alertas com até 48 horas de antecedência, com baixa taxa de falsos positivos.

Do ponto de vista metodológico, a principal contribuição até o momento é a estruturação de um modelo híbrido, que combina estatística clássica e inteligência artificial em um contexto ambiental complexo. A próxima etapa envolve a validação empírica do modelo com dados de campo e a comparação com sistemas de alerta existentes, como o BDQUEIMADAS.

Em síntese, embora os resultados finais ainda estejam em construção, os avanços metodológicos já demonstram o potencial do modelo como ferramenta de apoio à prevenção de incêndios e à responsabilização legal. A continuidade do trabalho dependerá da ampliação da base de dados, da validação estatística e da colaboração com instituições de monitoramento ambiental.

5. IMPLICAÇÕES E APLICAÇÕES

O modelo preditivo de incêndios florestais para a Amazônia Legal, ao integrar dados multifacetados e empregar metodologias avançadas, oferece implicações e aplicações práticas de grande relevância para a gestão ambiental, para a perícia e a justiça na região, conforme a seguir.

5.1. Prevenção Ativa de Incêndios Florestais

A principal aplicação do modelo está em sua capacidade de apoiar a prevenção ativa de incêndios florestais, ao identificar focos de calor precursores e áreas de alto risco. Isso permite a alocação estratégica e antecipada de recursos, otimizando a resposta e aumentando a eficácia das ações de combate.

Sistemas de alerta precoce baseados nas previsões do modelo podem transformar a gestão de incêndios ao fornecer informações em tempo real sobre regiões vulneráveis. Essa precisão permite medidas preventivas mais eficazes, como monitoramento intensivo, criação de aceiros e até evacuações, evitando a geração de falsos alarmes que possam comprometer a confiança no sistema.

Ao transformar dados em ação proativa, o modelo contribui para uma gestão de crises mais eficiente, permitindo intervenções antes que os focos se tornem incêndios de grandes proporções. Essa abordagem proativa reduz danos ambientais, econômicos e sociais, e representa uma mudança de paradigma em relação às estratégias tradicionais de resposta reativa (Singh et al. 2024)

5.2. Auxílio na Identificação de Responsáveis por Incêndios Criminosos

Outra das contribuições mais relevantes do modelo preditivo é seu potencial para apoiar a identificação de responsáveis por incêndios de origem criminosa, ampliando seu papel de ferramenta de gestão ambiental para instrumento de investigação de crimes. A análise de padrões de propagação do fogo, a localização de focos iniciais e a avaliação dos impactos no ambiente, com o uso de GIS e sensoriamento remoto, fornecem dados valiosos para as investigações criminais e administrativas.

Para que esses dados possam servir como prova em processos judiciais, o modelo precisa oferecer alta acurácia, granularidade e auditabilidade. A identificação precisa de focos precursores, a distinção entre incêndios reais e falsos positivos e a correlação entre padrões de incêndio e atividades humanas, como o desmatamento, são fundamentais para atribuir causalidade e responsabilizar os autores.

Assim, o modelo representa um avanço para a perícia e para a justiça ambiental ao fortalecer a capacidade do Estado de investigar e punir crimes ambientais. Sua aplicação pode desincentivar práticas ilegais e consolidar o uso de tecnologias de sensoriamento remoto e inteligência artificial na persecução penal e na proteção do meio ambiente.

6. CONCLUSÃO

O presente estudo propôs a estruturação de um modelo preditivo de incêndios florestais voltado para os biomas da Amazônia Legal, integrando dados meteorológicos, de cobertura vegetal, uso do solo e histórico de queimadas. Embora o modelo ainda esteja em fase de desenvolvimento e calibração, os avanços metodológicos já demonstram seu potencial como ferramenta estratégica para a prevenção de incêndios e a responsabilização de eventos de origem criminosa.

A abordagem adotada combina técnicas estatísticas robustas, como o método REML/BLUP, com algoritmos de aprendizado de máquina, como Random Forest, permitindo a identificação de padrões complexos e a adaptação a diferentes contextos espaciais e temporais. A utilização de dados multiescalares e multitemporais, validados por fontes confiáveis como o INMET, BDQUEIMADAS, NDVI e o Projeto RADAM, confere ao modelo uma base sólida para análises preditivas.

A proposta se destaca por sua capacidade de antecipar focos de incêndio com base em variáveis ambientais e antrópicas, contribuindo para uma gestão mais proativa e eficiente. Além disso, o modelo oferece suporte técnico para ações de fiscalização, perícia e justiça ambiental, ao gerar evidências georreferenciadas que podem ser utilizadas em processos de responsabilização.

Como próximos passos, destaca-se a necessidade de validação empírica do modelo com dados de campo, bem como a ampliação da base de dados para incluir variáveis socioeconômicas e climáticas adicionais. A colaboração com instituições públicas e centros de pesquisa será fundamental para consolidar o modelo como uma ferramenta de apoio à governança ambiental na Amazônia.

Em síntese, este trabalho representa um avanço significativo na construção de soluções tecnológicas voltadas à proteção dos ecossistemas amazônicos, alinhando ciência, inovação e responsabilidade socioambiental.

REFERÊNCIAS

Almeida, Cláudio Aparecido de, Alexandre Camargo Coutinho, Júlio César Dalla Mora Esquerdo, et al. 2016. "High Spatial Resolution Land Use and Land Cover Mapping of the Brazilian Legal Amazon in 2008 Using Landsat-5/TM and MODIS Data". *Acta Amazonica* 46 (setembro): 291–302. <https://doi.org/10.1590/1809-4392201505504>.

Aragão, Luiz E. O. C., e Yosio E. Shimabukuro. 2010. "The Incidence of Fire in Amazonian Forests with Implications for REDD". *Science*, advance online publication, junho 4. world. <https://doi.org/10.1126/science.1186925>.

Belgiu, Mariana, e Lucian Drăguț. 2016. "Random forest in remote sensing: A review of applications and future directions". *ISPRS Journal of Photogrammetry and Remote Sensing* 114 (abril): 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.

Bowman, David M. J. S., Jennifer K. Balch, Paulo Artaxo, et al. 2009. "Fire in the Earth System". *Science (New York, N.Y.)* 324 (5926): 481–84. <https://doi.org/10.1126/science.1163886>.

Giglio, Louis, Wilfrid Schroeder, e Joanne V Hall. [s.d.]. *MODIS Collection 6 and Collection 6.1 Active Fire Product User's Guide*. https://modis-fire.umd.edu/files/MODIS_C6_C6.1_Fire_User_Guide_1.0.pdf.

HRW, IEPS, e IPAM. 2020. "The Air Is Unbearable': Health Impacts of Deforestation-Related Fires in the Brazilian Amazon". *Human Rights Watch*, agosto 26. <https://www.hrw.org/report/2020/08/26/air-unbearable/health-impacts-deforestation-related-fires-brazilian-amazon>.

IBGE. 2018. "Vegetação | IBGE". IBGE. RADAMBRASIL: conjunto de dados históricos sobre a vegetação brasileira. <https://www.ibge.gov.br/geociencias/informacoes-ambientais/vegetacao.html>.

Jain, Piyush, Sean C. P. Coogan, Sriram Ganapathi Subramanian, Mark Crowley, Steve Taylor, e Mike D. Flannigan. 2020. "A review of machine learning applications in wildfire science and management". *Environmental Reviews* 28 (4): 478–505. <https://doi.org/10.1139/er-2020-0019>.

METER. 2023. "NDVI and PRI: The Researcher's Complete Guide". maio 1. <https://metergroup.com/education-guides/ndvi-and-pri-the-researchers-complete-guide/>.

Olafsson, H., I. Rousta, e J. Krzyszczyk. 2025. "Spatiotemporal dynamics and ANN-based projection of daytime and nighttime land surface temperature in Iceland (2001–2035)". *Modeling Earth Systems and Environment*, 353, vol. 11. <https://link.springer.com/article/10.1007/s40808-025-02558-x>.

Piepho, H. P., J. Möhring, A. E. Melchinger, e A. Büchse. 2008. "BLUP for Phenotypic Selection in Plant Breeding and Variety Testing". *Euphytica* 161 (1): 209–28. <https://doi.org/10.1007/s10681-007-9449-8>.

Resende, M. D. V. de. 2002. *Genética biométrica e estatística no melhoramento de plantas perenes*. Embrapa Informação Tecnológica: Colombo: Embrapa Floresta. <http://www.alice.cnptia.embrapa.br/handle/doc/306061>.

Resende, M. D. V. de, e J. A. Sturion. 2001. *Análise genética de dados com dependência espacial e temporal no melhoramento de plantas perenes via modelos geoestatísticos e de séries temporais empregando REML/BLUP ao nível individual*. Embrapa Florestas. <https://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/306131>.

Resende_1, M. D. V. de. 2007. *SELEGEN-REML/BLUP: sistema estatístico e seleção genética computadorizada via modelos lineares mistos*. Embrapa. <http://www.alice.cnptia.embrapa.br/handle/doc/290975>.

Singh Harikesh, Ang Li-Minn, Lewis Tom, et al. 2024. "Trending and emerging prospects of physics-based and ML-based wildfire spread models: a comprehensive review". *Journal of Forestry Research* 35 (1): 135. <https://doi.org/10.1007/s11676-024-01783-x>.

Soares-Filho, B. S., A. S. Oliveira, R. G. Rajão, et al. 2017. *Economic Valuation of Changes in the Amazon Forest Area: Economic Losses by Fires to Sustainable Timber Production*. Centro de Sensoriamento Remoto, Universidade Federal de Minas

Gerais (UFMG). http://csr.ufmg.br/amazones/wp-content/uploads/2017/06/Report_TimberandFire.pdf.

Yengoh, Genesis T, David Dent, Lennart Olsson, e Anna E Tengberg. 2014. *The Use of the Normalized Difference Vegetation Index (NDVI) to Assess Land Degradation at Multiple Scales: A Review of the Current Status, Future Trends, and Practical Considerations*. Lund University Center for Sustainability Studies (LUCSUS), and The Scientific and Technical Advisory Panel of the Global Environment Facility (STAP/GEF). <https://link.springer.com/book/10.1007/978-3-319-24112-8>.

Zeng, Yelu, Dalei Hao, Alfredo Huete, et al. 2022. "Optical Vegetation Indices for Monitoring Terrestrial Ecosystems Globally". *Nature Reviews Earth & Environment* 3 (7): 477–93. <https://doi.org/10.1038/s43017-022-00298-5>.

Zhalehdoost, A., e M. Taleai. 2025. "Unravelling the importance of spatial and temporal resolutions in modeling urban air pollution using a machine learning approach". *Scientific Reports*. <https://pubmed.ncbi.nlm.nih.gov/40731082/>.