



Universidade de Brasília – UnB
Instituto de Ciências Humanas – IH
Departamento de Geografia – GEA
Programa de Pós-Graduação em Geografia

Universidade de Brasília

Programa de Pós-graduação em Geografia (POSGEA)

**MODELAGEM DE OCORRÊNCIA DE INCÊNDIOS NA AMAZÔNIA
LEGAL USANDO APRENDIZAGEM DE MÁQUINA**

WILKISON QUEIROZ DE BRITO

Dissertação de Mestrado

**Brasília-DF
2023**



Universidade de Brasília – UnB
Instituto de Ciências Humanas – IH
Departamento de Geografia – GEA
Programa de Pós-Graduação em Geografia

Universidade de Brasília
Programa de Pós-graduação em Geografia (POSGEA)

**MODELAGEM DE OCORRÊNCIA DE INCÊNDIOS NA AMAZÔNIA
LEGAL USANDO APRENDIZAGEM DE MÁQUINA**

Dissertação de Mestrado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a qualificação, na linha de pesquisa em Geoprocessamento.

WILKISON QUEIROZ DE BRITO

Orientador: Osmar Abílio de Carvalho Júnior

Co-orientador: Pablo Pozzobon de Bem

Brasília-DF
2023

Universidade de Brasília
Programa de Pós-graduação em Geografia (POSGEA)

**MODELAGEM DE OCORRÊNCIA DE INCÊNDIOS NA AMAZÔNIA
LEGAL USANDO APRENDIZAGEM DE MÁQUINA**

Wilkison Queiroz de Brito

Dissertação de Mestrado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Mestre em Geografia, na linha de pesquisa em Geoprocessamento, opção Acadêmica.

Aprovado por:

Osmar Abílio de Carvalho Júnior, Doutor (GEA-UNB)
(Orientador)

Potira Meirelles Hermuche, Doutora (GEA-UNB)
potira@unb.br
(Examinador interno)

Giuliano Tostes Novais, Doutor (Universidade Estadual de Goiás - UEG)
giuliano.novais@ueg.br
(Examinador externo)

Brasília-DF, 28 de fevereiro de 2023

AGRADECIMENTOS

A Jeová-Deus por me guia no caminho da luz, nesse mundo tão caótico e a todas pessoas que contribuíram com minha formação.

Aos meus pais que sempre lutaram para me dar a melhor educação possível e com muita dedicação e esforço conseguiram, agradeço imensamente por isso.

Aos meus amigos que estão presente no meu cotidiano me apoiando e incentivando a buscar sempre a minha melhor versão.

A minha namorada (Thaís Oliveira) que sempre me ensinou a saber esperar o momento de Deus para as coisas acontecerem.

A Universidade de Brasília que me acolheu da melhor maneira, fazendo meus dias mais felizes e conhecendo um novo ambiente, já mais visto por mim.

Por fim, ao meu orientador que em meio a pandemia, ainda conseguiu me orientar e mediar seus conhecimentos, gratidão por todo ensinamento.

RESUMO

Análise de Aprendizado de Máquina Aplicada a Ocorrência de Focos de Incêndio na Amazônia Legal

A Amazônia legal possui a maior cobertura florestal da Terra, desempenhando um papel fundamental para a sequestro de carbono, conservação da biodiversidade e regulação do clima. No entanto, nas últimas décadas, a conversão de áreas de vegetação natural em áreas agrícolas, desmatamento seletivo e efeitos de mudança climáticas tem induzido o aumento de eventos de queimadas. Essa pesquisa possui como objetivo analisar modelos baseados em métodos de aprendizagem de máquina para prever as áreas mais vulneráveis à ocorrência de incêndios na região da floresta amazônica brasileira. Os métodos de aprendizagem de máquina testados foram o Random Forest (RF), Extreme Gradient Boost (XGB) e Multilayer Perceptron (MLP). O processamento de dados utilizou diferentes feições da paisagem que condicionam a variação espacial da ocorrência de incêndios, incluindo: áreas desmatadas, cidades, estradas, bordas de florestas e dados climáticos (temperatura média da superfície terrestre e precipitação média). A análise de precisão usou a curva Receiver Operating Characteristic (ROC), comparando os resultados dos modelos de aprendizado de máquina e os focos de incêndios provenientes do banco de dados BDQueimadas desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE). A otimização dos hiperparâmetros dos modelos considerou os valores de acurácia, objetivando a aprimoração dos modelos na obtenção dos melhores resultados. Apesar dos modelos apresentarem desempenho semelhantes, o melhor modelo foi o RF com valores de Área Abaixo da Curva (AUC) de 0,88 seguido do MLP e XGB com AUC de 0,84. No entanto, a modelagem considerando a inserção de estradas planejadas no modelo corrobora uma maior variação usando o método MLP. Os resultados evidenciam a interferência humana na indução das queimadas. Trabalhos futuros devem ser desenvolvidos para o aprimoramento da metodologia proposta, principalmente inserido outras variáveis ambientais e antrópicas e comparando com outros métodos de inteligência artificial.

Palavras-chave: incêndio florestal, inteligência artificial, aprendizado de máquina, análise espacial, modelos preditivos.

ABSTRACT

Machine Learning Analysis Applied to the Occurrence of Fire Spots in the Legal Amazon

The Brazilian Legal Amazon has the most extensive forest cover on Earth, playing a pivotal role in carbon sequestration, biodiversity conservation, and climate regulation. However, in recent decades, the conversion of areas of natural vegetation into agricultural areas, selective deforestation, and the effects of climate change have increased fire events. This research aims to analyze models based on machine learning methods to predict the most vulnerable areas to fire occurrences in the Brazilian Amazon Forest region. The tested machine learning methods were Random Forest (RF), Extreme Gradient Boost (XGB), and Multilayer Perceptron (MLP). Data processing uses different landscape characteristics that condition the spatial variation in the occurrence of fires, including deforested areas, cities, roads, forest edges, and climate data (average temperature of the Earth's surface and average precipitation). The accuracy analysis used the Receiver Operating Characteristic (ROC) curve, comparing the results of machine learning models and active fires from the BDQueimadas database developed by the National Institute for Space Research (INPE). Optimizing the method's hyperparameters considered accuracy values, aiming to improve the models to obtain the best results. Despite the models presenting similar performance, the best model was the RF with Area Under the Curve (AUC) values of 0.88, followed by MLP and XGB with AUC of 0.84. However, the modeling considering the inclusion of planned roads presents a more significant variation using the MLP method. The results show human interference in the induction of fires. Future studies should be developed to improve the proposed methodology, mainly by inserting other environmental and anthropic variables and comparing them with other artificial intelligence methods.

Keywords: forest fire, artificial intelligence, machine learning, spatial analysis, predictive models.

SUMÁRIO

1. INTRODUÇÃO	12
2. ÁREA DE ESTUDO	16
3. MATERIAL E MÉTODOS	17
3.1 Dados dos Focos de Incêndios (variável dependente).....	17
3.2 Dados de Rodovias e Centros Urbanos a partir do OpenStreetMap (variáveis independentes).....	18
3.3 Dados Climáticos (variáveis independentes)	20
3.4 Procedimento de Amostragem	20
3.5 Modelos	22
3.6 Análise de acurácia dos modelos	23
4 RESULTADOS.....	24
4.1 Resultados dos grupos de Validação.....	24
4.2 Avaliação final	26
4.3 Mapas de probabilidade	28
5 DISCUSSÃO	32
6 CONCLUSÃO	33
7 REFERÊNCIAS	34

LISTA DE FIGURAS

Figura 1 - Vegetação Nativa; 2-Desmatamento; 3-Queimada; 4-Agricultura e Pastagem.	13
Figura 2 - Evolução anual das áreas queimadas entre 2002 e 2020.	16
Figura 3 - Localização da área de estudo.	17
Figura 4 - Distribuição de focos detectados pelo INPE em 2021.	18
Figura 5 - Divisão espacial das amostras de treinamento para validação cruzada.	21
Figura 6 - Processo de divisão de amostras neste trabalho.	22
Figura 7 - Curvas ROC para cada modelo e grupo de validação.	25
Figura 8 - Curvas ROC médias de treinamento e teste dos modelos.	27
Figura 9 - Mapa de probabilidade de presença de focos segundo os modelos MLP, RF e XGB, considerando as estradas atuais em atividade.	29
Figura 10 - Mapa de probabilidade de presença de focos dos modelos MLP, RF e XGB com a adição de rodovias planejadas.	30
Figura 11 - Mapa de diferença de probabilidades entre os mapas sem e com rodovias planejadas para os modelos MLP, RF e XGB.	31

LISTA DE TABELAS

Tabela 1 - Valores da área abaixo da curva (AUC) ROC para cada modelo e grupo de validação.	26
Tabela 2 - Valores da área abaixo da curva ROC médias de treinamento e teste dos modelos.	28

LISTA DE ABREVIATURAS E SIGLAS

ANN – Redes Neurais Artificiais

AUC – Area Under The Curve

CHIRPS – Climate Hazards group Infrared Precipitation with Stations

XGB – Extreme Gradient Boosting

FN – Falso Negativo

FP – Falso Positivo

GPS – Global Position System

IBAMA – Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis

MODIS – Moderate Resolution Imaging Spectroradiometer

MLP – Multilayer Perceptron

OSM – OpenStreetMap

RF – Random Forest

ROC – Receiver Operating Characteristic

S-NPP – Suomi-National Polar-orbiting Partnership

SVM – Máquina de Vetores de Suporte

TVP – Taxa Verdadeiro Positivo

TFP – Taxa Falso Positivo

VIIRS – Visible Infrared Imaging Radiometer Suite

VP – Verdadeiro Positivo

1. INTRODUÇÃO

A Amazônia Legal contém a mais extensa cobertura florestal e riqueza em biodiversidade do planeta, desempenhando um papel fundamental para a regulação do clima em ambos hemisféricos (Fu et al., 2013; Malhi et al., 2008), sequestro de carbono (Gatti et al., 2021; Rappaport et al., 2018), conservação da biodiversidade (Barlow et al., 2016), regulação do balanço hídrico e do fluxo do rio (Cavalcante et al., 2019; Costa and Foley, 1997; Lopes et al., 2021), manutenção de povos indígenas (Franco-Moraes et al., 2021; Urzedo and Chatterjee, 2021) e saúde (Butt et al., 2020; de Vasconcellos et al., 2021; Gonçalves et al., 2012). No entanto, o desflorestamento da Amazônia tem sido expressivo nas últimas décadas, atingindo um pico histórico em 2004 com uma área desmatada de 27,772 km². Após esse evento, houve um expressivo esforço governamental e intervenções nas cadeias produtivas da soja (moratória da soja) e carne bovina que proporcionaram uma significativa redução na taxa de desmatamento, atingindo 84% no ano de 2012 (Maranhão et al., 2019; Mello and Artaxo, 2017). No entanto, gradativamente o desmatamento vem novamente aumentando, atingindo em 2020 a maior taxa de desmatamento da década (Silva Junior et al., 2021).

A ocorrência de incêndios está intimamente relacionada com as ações antrópicas de desmatamento e uso da terra. Normalmente, as florestas primárias com dossel fechado possuem resistência ao fogo por possuírem densas copas foliares mesmo em períodos de estiagem, usando suprimentos de água do solo profundo (Nepstad et al., 1994). Portanto, a presença de ignições naturais de incêndios na floresta Amazônica é rara, mesmo com a alta ocorrência de raios entre os meses de setembro e novembro (Christian et al., 2003). A perda de resistência ocorre pelas ações antrópicas (corte seletivo e ações do fogo com adelgaçamento do dossel), com aumento da camada de combustível do solo da floresta e mudança do microclima no interior da floresta que se torna mais quente e seco. Apesar da resistência inicial da floresta, os incêndios repetidos reduzem a cobertura do dossel e favoreceram gramíneas invasoras (Balch et al., 2015). As áreas mais vulneráveis são as bordas da floresta, com maior suscetibilidade ao ressecamento, intensidade do fogo e invasão de gramíneas são maiores (Broadbent et al., 2008; Cochrane and Laurance, 2002; Laurance et al., 2002). As reincidências de severos períodos de seca em regiões de borda de florestas tornam-se fortes indutores de incêndios de grandes proporções (Silvério et al., 2019).

A utilização do fogo torna-se um instrumento de fácil emprego desde o processo de desmatamento, a partir da prática do corte seguido da queima para a abertura de florestas (Tremblay et al., 2015), até nas atividades agropecuárias, onde é empregado para preparar,

capinar e fertilizar a terra por pequenos até grandes proprietários de terras (Cabral et al., 2013; Morello et al., 2017) (Figura 1). Em adição, incêndios acidentais de larga escala são provocados a partir do manejo de fogo em terras agrícolas adjacentes que expandem sobre a floresta degradada, causando danos econômicos para o proprietário (agravos de cercas e redução da capacidade de pastoreio) e prejuízos ambientais (de Mendonça et al., 2004). Assim, a diminuição da taxa de desmatamento não significa uma diminuição de incêndios devido a sua permanência nas atividades agropecuárias. A adoção de medidas de manejo de terras sem fogo pode reduzir substancialmente a incidência de incêndios em até 69% em relação às áreas com manejo do fogo (Aragão and Shimabukuro, 2010).




Figura 1 - Vegetação Nativa; 2-Desmatamento; 3-Queimada; 4-Agricultura e Pastagem.

As alterações antrópicas promovem um estresse ecossistêmico que induz a uma retroalimentação negativa que intensifica a probabilidade de ocorrência de incêndios devido às mudanças nas interações ecossistema-clima. A remoção das florestas causa um aumento na temperatura, a remoção das florestas causa um aumento na temperatura do ar e na evapotranspiração potencial (ETP) e reduz a precipitação devido principalmente a falta de árvores, que acrescentam água na atmosfera através da transpiração, e reduz a precipitação a favor do vento em áreas desmatadas. Além disso, as mudanças na estrutura da floresta e composição de espécies provenientes dos distúrbios antrópicos devido à extração seletiva de madeira, desmatamento progressivo com isolamento de remanescentes florestais, e mudanças climáticas favorecem a ocorrência de incêndios em áreas florestadas. A associação do

desmatamento e de incêndios provoca uma significativa perda de habitat com acentuados impactos negativos na biodiversidade amazônica, havendo uma estreita relação da frequência de incêndios e os impactos na biodiversidade (Feng et al., 2021). A sinergia múltipla desses fatores antrópicos impactam conjuntamente para uma grande perda de florestas tropicais (Cabral et al., 2013; Cochrane and Laurance, 2008). Essas mudanças sistêmicas podem afetar a estabilidade das florestas em escala regional que pode atingir um “ponto de inflexão” onde a floresta perde a capacidade de recuperação (Arvor et al., 2018; Franklin and Pindyck, 2018; Lima et al., 2021; Lovejoy and Nobre, 2019; Nobre and Borma, 2009). Nesse cenário, a associação da expansão da conversão das florestas por pastagens, fragmentação florestal, inibição das chuvas e aumento de incêndios provocará um processo de savanização (Nepstad et al., 2008; Wuyts et al., 2017).

A evolução da área queimada no domínio da Amazônia Legal Brasileira totaliza cerca de 124.996 milhões de hectares no período de 19 anos (2002-2020) (**Figura 2**). A média de queimadas nesse período foi de cerca de 6.578 ha por ano, com maior proporção nos anos de 2005 (11.501 ha) e 2007 (11.197 ha) e menor proporção nos anos de 2013 (2.297 ha) e 2018 (3.525 ha). Nesse período os anos que ficaram acima da média registrada de queimas na área de estudo foram: 1987; 1988; 1995; 1996; 1997; 1998; 1999; 2000; 2001; 2002; 2003; 2004; 2005; 2006; 2007; 2008; 2010. As áreas de maior ocorrência de fogo na região Amazônica estão na fronteira agrícola, avançando em direção a floresta denominada de arco do desmatamento, contendo os maiores índices de desmatamento da Amazônia e localiza principalmente nos estados de Rondônia, Pará e Mato Grosso (Morton et al., 2013; Schroeder et al., 2009). O processo de corte e queima das áreas florestais tem avançado cada vez mais nos territórios da Floresta Amazônia, no ano de 2005, aproximadamente 90% das áreas desmatadas no sudeste de Rondônia e noroeste de Mato Grosso foram as principais áreas de queimadas (Lima et al., 2012).

O controle e diminuição dos desmatamentos e incêndios na Amazônia deve atuar com instrumentos de monitoramento, comando e controle e políticas baseados em incentivos (Fearnside, 2006; Morello et al., 2017). Nesse contexto, técnicas de sensoriamento remoto são fundamentais para monitoramento devido a sua rapidez e eficiência na detecção de incêndios florestais ativos e de áreas queimadas (Bowman et al., 2009; Santana et al., 2018; Shimabukuro et al., 2015).

Outra importante ferramenta é a utilização de método preditivos de incêndios que orientam o combate e permitem a mitigação desses eventos. Os modelos de previsão são baseados em métodos estatísticos ou algoritmos de aprendizagem de máquina que permitem

calcular a probabilidade de ocorrência de um dado, através da utilização das variáveis independentes (topografia, tipo de vegetação, clima, entre outros) para uma variável resposta (número de focos, quantidade de área queimada, entre outros). Diferentes modelos têm sido empregados para a predição de áreas vulneráveis à incêndios, destacando os métodos de regressão, análise de decisão multicritérios, e métodos de aprendizagem de máquina. Diversos modelos de regressão estão sendo utilizados para a predição de incêndios, tais como: regressão logística ([Chang et al., 2013](#); [Eskandari and Chuvieco, 2015](#); [Guo et al., 2016a](#); [Mohammadi et al., 2014](#); [Zhang et al., 2016](#)), regressão de Poisson ([Boubeta et al., 2015](#); [Graff et al., 2020](#)), regressão geograficamente ponderada ([Monjarás-Vega et al., 2020](#); [Oliveira et al., 2014](#)), regressão logística geograficamente ponderada ([Rodrigues et al., 2014](#)), e Splines de Regressão Adaptativa Multivariada ([Amatulli et al., 2013](#)). A análise de decisão multicritério é um método de tomada de decisão que avalia e compara várias fatores vulnerabilidade aos incêndios, sendo amplamente utilizado ([Cipriani et al., 2011](#); [Eugenio et al., 2016](#); [Jung et al., 2013](#); [Kayet et al., 2020](#); [Kumari and Pandey, 2020](#); [Sari, 2021](#)). Por fim, vários estudos tem utilizado técnicas de aprendizado de máquina (onde vários comparam com a regressão logística), tais como Redes Neurais Artificiais (ANN) ([Adab, 2017](#); [de Bem et al., 2019](#); [Goldarag et al., 2016](#)), árvore de decisão (ID3 e C.45) ([Sitanggang et al., 2013](#)), Random Forest (RF) ([Amatulli et al., 2013](#); [Guo et al., 2016b](#); [Ma et al., 2020](#); [Milanović et al., 2020](#)), and Support Vector Machines (SVM) ([Jaafari and Pourghasemi, 2019](#)). Complementarmente, algumas pesquisas comparam várias técnicas de aprendizado de máquina tais como: RF, Boosting Regression Trees (BRT), SVM, Logistic Regression ([Rodrigues and de la Riva, 2014](#)), e Redes Neurais Artificiais, SVM, e RF ([Ghorbanzadeh et al., 2019](#)).

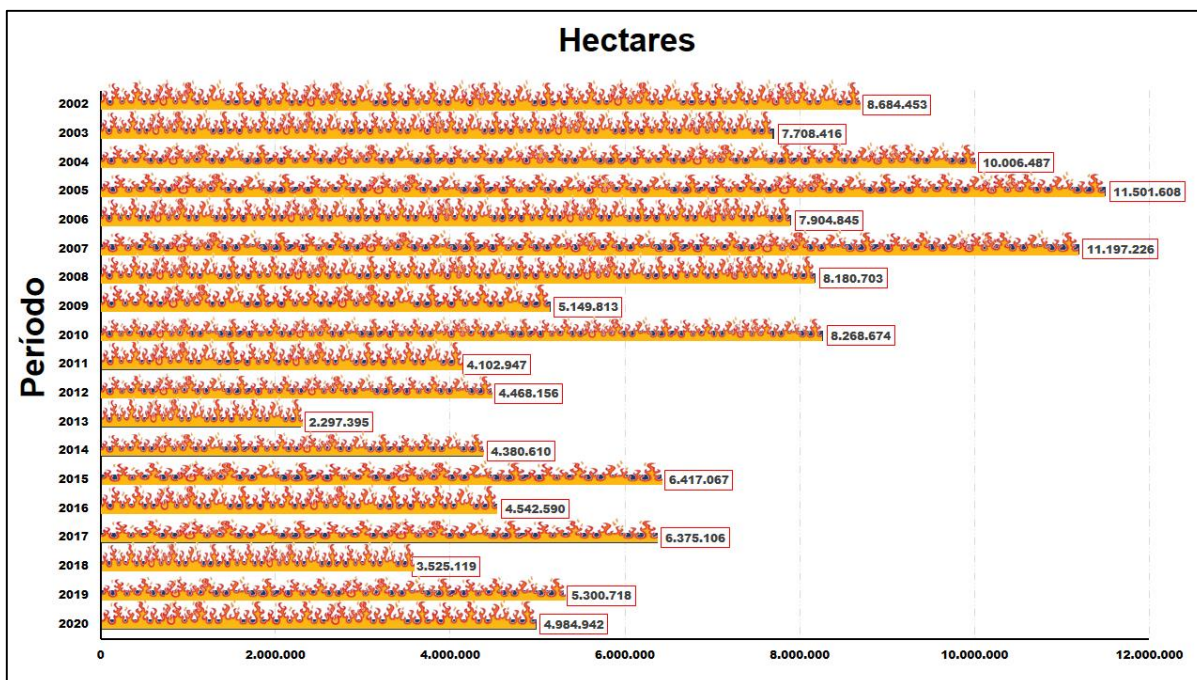


Figura 2 - Evolução anual das áreas queimadas entre 2002 e 2020.

O presente trabalho possui como objetivo de avaliar e comparar modelos utilizados para identificação de áreas susceptíveis aos focos de incêndios na Amazônia Legal. Os objetivos específicos são: discriminar os focos de incêndios presente dentro recorte temporal; identificar as principais variáveis independentes e dependentes que impulsionam os focos de incêndios; e qualificar um modelo que represente o comportamento espacial do fogo.

2. ÁREA DE ESTUDO

A área de estudo compreende a Amazônia Legal Brasileira (**Figura 3**), uma área político-administrativa instituída pelo Governo brasileiro conforme a lei número 1806 de 06/01/1953 (Brasil, 1953). A Amazônia Legal abrange os limites da Bacia hidrográfica do Rio Amazonas, compreendendo os Estados do Amazonas (AM), Pará (PA), Roraima (RR), Rondônia (RO), Acre (AC), Amapá (AP), Tocantins (TO), Mato Grosso (MT) e parte do Maranhão (MA) com uma área total de 5,2 milhões de km² que corresponde a 61% do território brasileiro. A região apresenta clima tropical chuvoso (chuvas do tipo monção), correspondendo a classe “Am” na classificação de Koppen com temperaturas médias altas (variando de 25°C até 27°C), elevada radiação solar, totais pluviométricos médios anuais de 2500 mm e umidade relativa do ar entre 85 e 90%, na parte mais úmida (Centro-Noroeste do Amazonas) é o clima Af, por fim, na região da Amazônia Meridional, limite com o Cerrado é o clima do Aw. (Fisch et al., 1998; Pavão et al., 2015). Essa região apresenta vastas planícies fluviais, caracterizadas por terrenos baixos e elevada riqueza mineral e elas acompanham os vales dos principais rios,

foram dessas áreas, existe tabuleiros, colinas, depressões e planaltos residuais, ocupando a maior parte da área da Amazônia Legal. (Ferreira and Salati, 2005).




Figura 3 - Localização da área de estudo.

3. MATERIAL E MÉTODOS

3.1 Dados dos Focos de Incêndios (variável dependente)

O presente estudo utilizou os focos de calor presente no banco de dados denominado BDQueimadas (www.inpe.br/queimadas/bdqueimadas) desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) a partir dos dados do sensor Moderate Resolution Imaging Spectroradiometer (MODIS) a bordo dos satélites AQUA e Terra a partir de 1998 e do sensor Visible Infrared Imaging Radiometer Suite (VIIRS) do satélite Suomi-National Polar-orbiting Partnership (S-NPP) gerados a partir de 2019 (Figura 4). O BDQueimadas é um aplicativo WebGIS desenvolvido a partir de geotecnologias abertas com dados geográficos gerenciados por PostgreSQL. O banco de dados inclui dados diários provenientes de mais de 200 imagens processadas especificamente para detectar focos de queima de vegetação em toda América Latina. A partir dos dados diários dos focos é possível estabelecer uma composição para um intervalo da série temporal e comparações temporais e espaciais para intervalos maiores que 10 dias. No entanto, os dados não devem ser considerados medida absoluta da ocorrência de fogo.

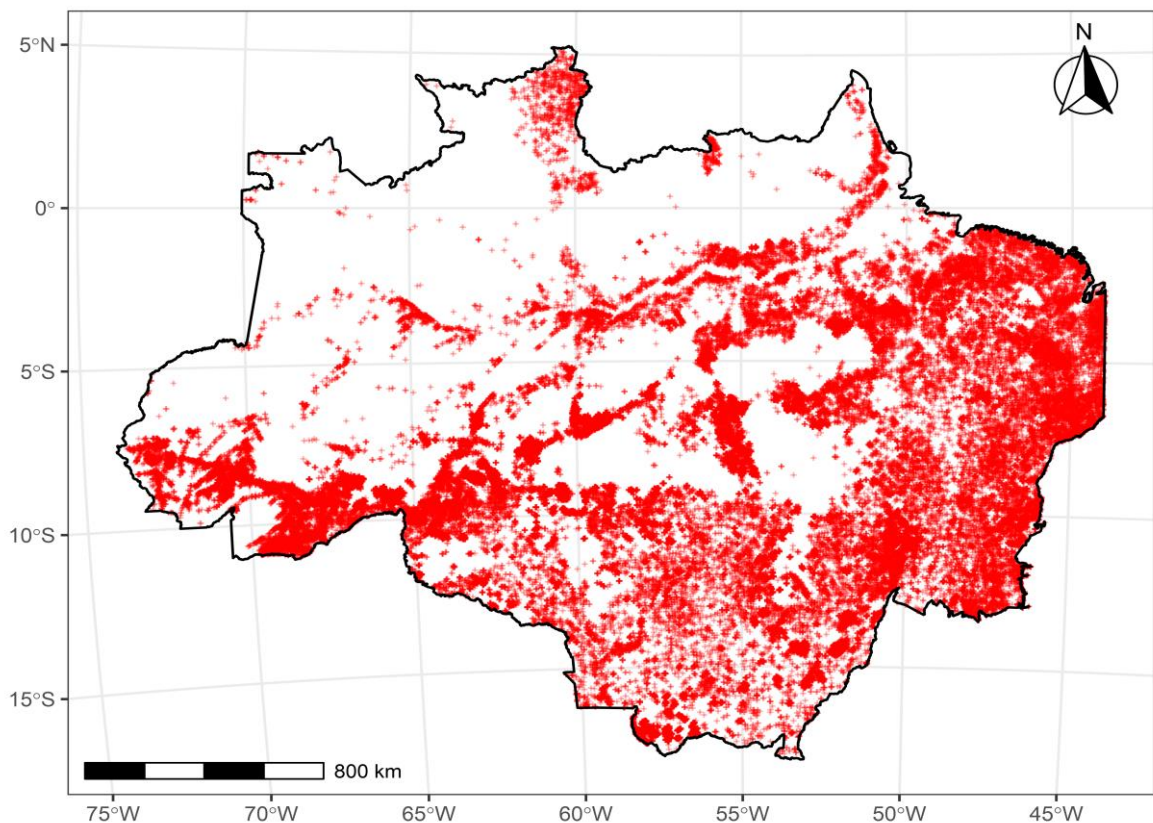


Figura 4 - Distribuição de focos detectados pelo INPE em 2021.

A presente pesquisa filtrou as ocorrências de incêndios do ano de 2021 nos limites da Amazônia Legal. A ocorrência dos focos de calor foi considerada a classe de presença no processo de modelagem. A classe de ausência foi elaborada através da criação de pontos aleatórios na área de estudo, considerando uma distância mínima de 2 quilômetros entre pontos de ausência e presença.

3.2. Dados de Rodovias e Centros Urbanos a partir do OpenStreetMap (variáveis independentes)

Neste estudo foram utilizados dados de rodovias e centros urbanos disponíveis na base OpenStreetMap (OSM), que fazem parte do conjunto de variáveis independentes utilizadas na modelagem de incêndios. O projeto OSM é uma iniciativa de mapeamento colaborativo que começou em 2004 que permite a construção de uma base de dados geográficos aberta e gratuita do mundo a partir da mobilização comunitária, denominada de Wikipedia dos mapas por atingir o auge da informação geográfica voluntária e colaborativa (Bertolotto et al., 2020; Neis and Zielstra, 2014). A construção colaborativa da base de dados vetoriais utiliza diversas estratégias para mapeamento, tais como o uso de dispositivos de GPS, fotogrametria, análise de imagens de satélite, entre outros (https://wiki.openstreetmap.org/wiki/Mapping_techniques). Portanto,

desde o seu surgimento, gradativamente aumenta o engajamento pelas comunidades de mapeamento voluntário, organizações governamentais, instituições humanitárias e privadas na colaboração de preenchimento de lacunas de dados e aplicações para diversas finalidades. Dentre as diferentes aplicações do uso do OSM, pode-se citar a redução do risco de desastres (Goldblatt et al., 2020; Scholz et al., 2018), classificação do uso e cobertura da terra (Fonte et al., 2015), planejamento de rotas urbanas (Neis, 2015; Novack et al., 2018), visualização e modelagem 3D de cidades (Over et al., 2010), entre outros. Apesar da maior contribuição na inserção de dados a partir de regiões com Índice de Desenvolvimento Humano alto, esforços de mapeamento concentram principalmente em regiões com desenvolvimento humano médio e baixo (Herfort et al., 2021). Além disso, busca-se também um maior engajamento da comunidade acadêmica para uma validação dos dados (Grinberger et al., 2022).

Os dados de rodovias no OSM são categorizados em diversos valores em função do tipo e importância das vias (<https://wiki.openstreetmap.org/wiki/Key:highway>). As seguintes categorias foram selecionadas e agrupadas em três grupos em função de níveis hierárquicos para uso neste estudo:

- As categorias *motorway*, *trunk*, *primary* e *primary-link* foram agregadas em um grupo como rodovias **primárias**, representando grandes vias tais como rodovias nacionais.
- As categorias *secondary* e *secondary-link* foram consideradas rodovias **secundárias**, representando vias de menor extensão tais como rodovias estaduais;
- As categorias *tertiary*, *tertiary-link*, *track* e *unclassified* foram agregadas em um grupo como rodovias **terciárias**, representando pequenas vias de menor importância.

Similarmente, os dados de locais ou centros urbanos são categorizados em função de sua função e nível hierárquico (<https://wiki.openstreetmap.org/wiki/Key:place>). Nesta pesquisa foram selecionados pontos representando as categorias “city” (grandes centros urbanos como capitais), “town” (centros urbanos médios) e “village” (pequenos centros urbanos ou agrupamentos tais como vilas e aldeias).

Os dados vetoriais das rodovias e centros urbanos foram utilizados como variáveis independentes no processo de modelagem. Os dados vetoriais foram convertidos em dados matriciais e gerado a distância euclidiana para cada feição vetorial, com cada pixel resultante representando o valor da distância até a feição mais próxima (por exemplo, distância à rodovia primária mais próxima, ou distância ao grande centro urbano mais próximo). A resolução espacial utilizada para a criação destes dados matriciais foi de 500 metros.

Complementarmente, os dados OpenStreetMap contam com dados de rodovias planejadas, inseridos como rodovias primárias em outra modelagem separada para avaliar o possível impacto com a construção dessas novas rodovias.

3.3 Dados Climáticos (variáveis independentes)

Este estudo usou dois tipos de dados climáticos: temperatura média da superfície terrestre e precipitação média observadas no ano de 2021. A média da temperatura da superfície terrestre foi calculada a partir de dados do produto MOD11A2 do sensor MODIS (<https://lpdaac.usgs.gov/products/mod11a2v061/>), que apresenta estimativas da temperatura da superfície em uma resolução espacial de 1km por pixel. Os valores de temperatura, originalmente dados em Kelvin (K), foram convertidos para celsius (C). A média da precipitação para o ano de 2021 foi calculada a partir de dados encontrados na base de dados *Climate Hazards group Infrared Precipitation with Stations* (CHIRPS), cujo objetivo é elaborar mapas de precipitação a partir de dados de imagens de sensoriamento remoto e dados de estações climatológicas (<https://www.nature.com/articles/sdata201566>, <https://pubs.usgs.gov/ds/832/>).

3.4 Procedimento de Amostragem

O total de observações foi de 204298 amostras, incluindo as classes de presença e ausência de focos. Estas observações foram primeiramente divididas em dois grupos amostrais: treinamento e teste. O primeiro grupo foi utilizado para treinar, otimizar e validar os modelos. O segundo grupo foi utilizado para testar e avaliar o modelo treinado com a amostra de treinamento.

O método de validação utilizado foi a cruzada utilizando 5 sub amostras do treinamento. As amostras foram separadas espacialmente através do método de agrupamentos (*clustering*) espacial (Figura 5). Isto é feito para reduzir o viés causado pela autocorrelação espacial de pontos, fenômeno que tende a mascarar o desempenho real dos modelos. Modelos isolados são treinados com cada subgrupo e validados ao aplicá-los aos demais grupos. A **Figura 6** demonstra a divisão espacial das amostragens.

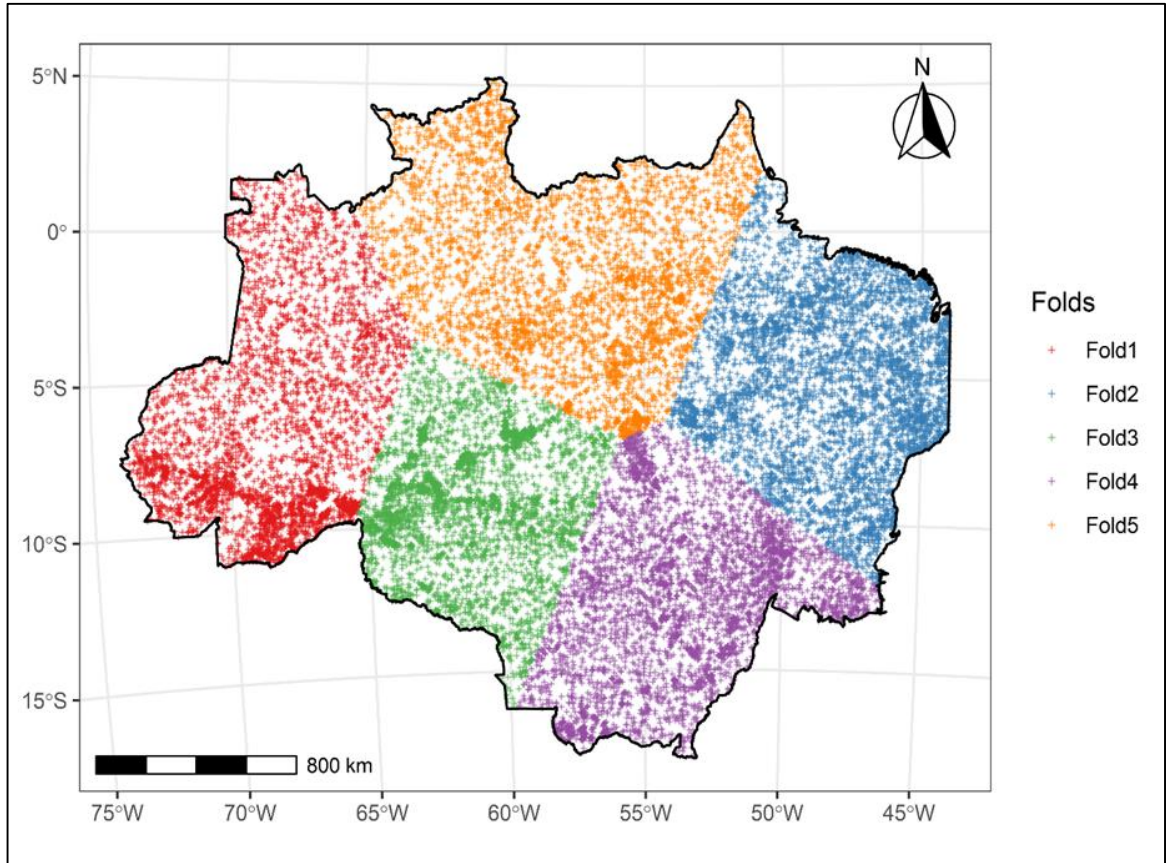


Figura 5 - Divisão espacial das amostras de treinamento para validação cruzada.

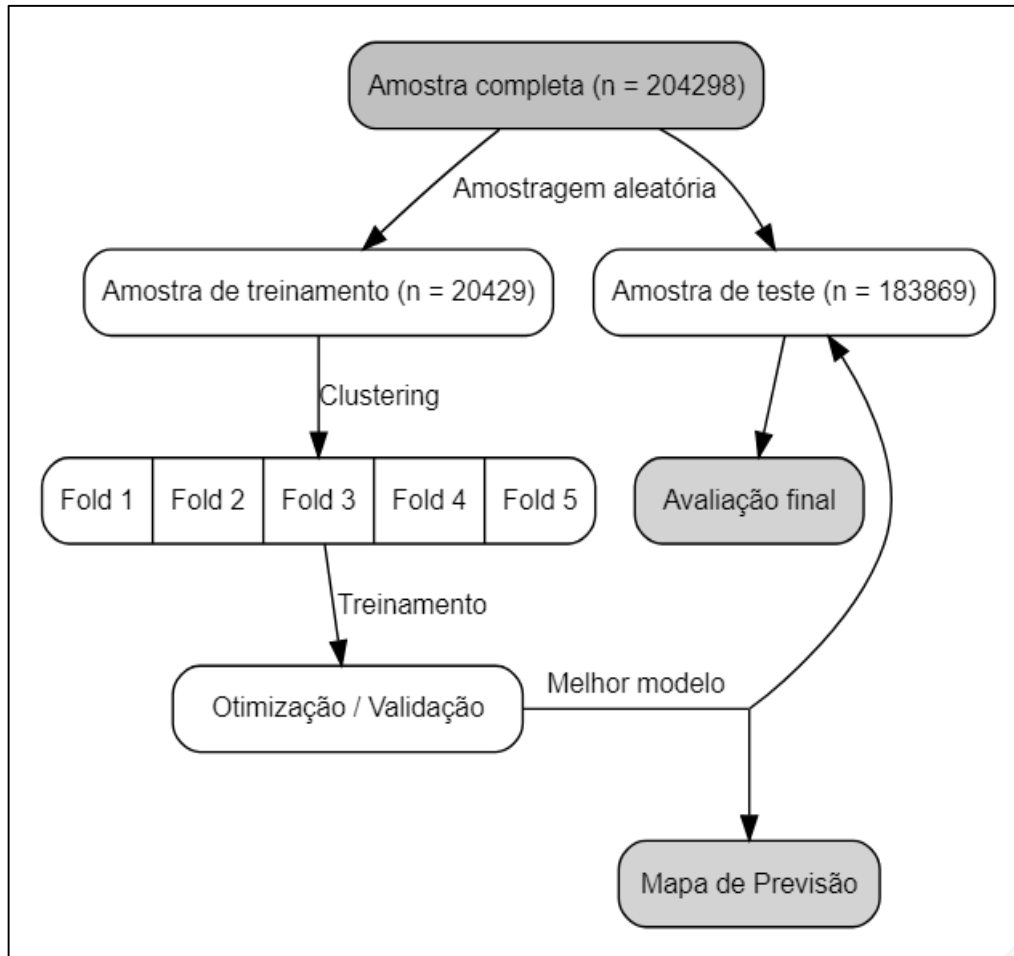


Figura 6 - Processo de divisão de amostras neste trabalho.

3.5 Modelos

Os seguintes modelos foram escolhidos para prever a ocorrência espacial de focos:

Random Forest (RF)

Random Forest (RF) (Breiman, 2001) combina um grande conjunto de árvores de classificação binárias, obtendo como resultado o voto majoritário de todas as árvores individuais (Genuer et al., 2010). A concepção do método é que muitos modelos relativamente não correlacionados votando performam melhor do que um único modelo, estabelecendo um método de aprendizagem conjunta ou múltipla (ensemble learning).

Extreme Gradient Boost (XGB)

O modelo Extreme Gradient Boosting (XGB) (Chen and He, 2014) é uma implementação eficiente do Gradient Boosting para a solução dos problemas de classificação e regressão. Ao contrário do Random Forest, o XGB constrói árvores pequenas e diferentes, treinando-as em subamostras dos dados de treinamento. Esses métodos usam “boosting” para

combinar previsões de diferentes classificadores, tentando determinar iterativamente os melhores pesos de cada classificador de acordo com uma determinada função de perda. Em linhas gerais, o método utiliza a estrutura de Gradient Boosting que minimiza os erros pela aplicação de um gradiente descendente e um poderoso método de otimização numérica, eliminando candidatos menos qualificados.

Multilayer Perceptron (MLP)

O modelo Multilayer Perceptron (MLP) é uma rede neural artificial feedforward composta por múltiplas camadas de nós interconectados, onde a informação transcorre em apenas em uma direção da entrada para a saída (Murtagh, 1991). A rede neural é formada por uma camada de entrada que recebe os dados, camadas ocultas com um número indeterminado de neurônios que processa os dados gerando saídas intermediárias e uma camada de saída responsável pela previsão final. Cada camada contém neurônios, e os neurônios dentro de cada camada se conectam com os neurônios das próximas camadas por meio de conexões ponderadas. Nas arquiteturas MLP, existe uma variação do número de camadas escondidas e do número de nós em cada camada dependendo de sua aplicação (Baum, 1988). Os pesos se adaptam ao longo do treinamento, modificando os valores contidos em cada neurônio para melhor adequação aos dados e minimizar os erros entre a previsão e o dado real. O neurônio da camada de saída na classificação binária corresponde à probabilidade da classe determinada. Os MLPs são utilizados para tarefas de classificação e regressão, sendo uma técnica popular e amplamente utilizada no campo de redes neurais artificiais.

3.6. Análise de acurácia dos modelos

A análise de acurácia utilizou a curva ROC (Receiver Operating Characteristic), uma métrica bidimensional que avalia a performance de uma classificação que se baseia na representação gráfica de dois índices de acurácia: sensibilidade (taxa de verdadeiros positivos) e especificidade (taxa de falsos positivos, também denominado de Recall) (Marzban, 2004). Essas duas métricas de acurácia são amplamente usadas na avaliação de classificação binária, evidenciando o desempenho na classificação correta de casos positivos e negativos. A TVP expressa a proporção de casos positivos classificados corretamente como positivos (VP), enquanto a TFP é a proporção de casos negativos classificados incorretamente como positivos (FP), descritos pelas seguintes equações:

$$TVP = \frac{VP}{VP + FN}$$

$$TFP = \frac{FP}{FP + VN}$$

Onde “FN” representa a quantidade de Falsos Negativos e “VN” a quantidade de Verdadeiros Positivos.

Um classificador ideal teria um TVP de 1 e um TFP de 0, o que significa que classificaria corretamente todos os casos positivos e negativos. Graficamente, quanto mais próxima à curva ROC estiver do canto superior esquerdo, melhor será o modelo na classificação de casos positivos sem incorrer em muitas classificações de falsos positivos. A curva ROC também permite a determinação do limite ideal de previsões, selecionando o ponto que equilibra a necessidade de alto TPR e baixo FPR. A área sob a curva ROC (Area Under The Curve - AUC) é uma das principais métricas utilizadas na avaliação de modelos de classificação binária (como o nosso caso de presença ou não de incêndios), sendo frequentemente usada como uma única métrica escalar para resumir o desempenho geral de um modelo, com um valor de 1 indicando um classificador perfeito e um valor de 0,5 indicando um classificador aleatório (Faraggi and Reiser, 2002).

4 RESULTADOS

4.1 Resultados dos grupos de Validação

A **Figura 7** demonstra os resultados das curvas ROC para os cinco conjuntos de treinamentos dos modelos MLP, RF e XGB, enquanto a **Tabela 1** lista os respectivos valores referentes às AUC-ROC curvas. A presente análise avalia a acurácia da previsão de ocorrência de focos de incêndios. Os valores da curva ROC apresentam resultados satisfatórios nos três modelos (Mohajane et al., 2021; Pourghasemi et al., 2020). Os modelos baseados em árvore de decisão (RF e XGB) tiveram comportamento muito similares para os diferentes grupos, havendo um melhor desempenho nos grupos 1 e 5. Essas duas áreas de amostragem estão posicionadas na porção mais ao norte com menor ocorrência de incêndios, principalmente o grupo 5 (**Figura 5**). Dentre os melhores resultados do MLP, o grupo 5 permanece como nos métodos RF e XGB, mas o grupo 1 é substituído pelo grupo 2 que se posiciona na porção nordeste com alta dispersão de eventos de incêndio. Nos três modelos, os grupos com menores ajustes estão posicionados na porção sul da Amazônia onde o desmatamento é mais pronunciado. Dentre todos os modelos e áreas de análise, o melhor modelo foi o XGB para o grupo 1 (91%) e o pior foi RF para o grupo 2 (58%).

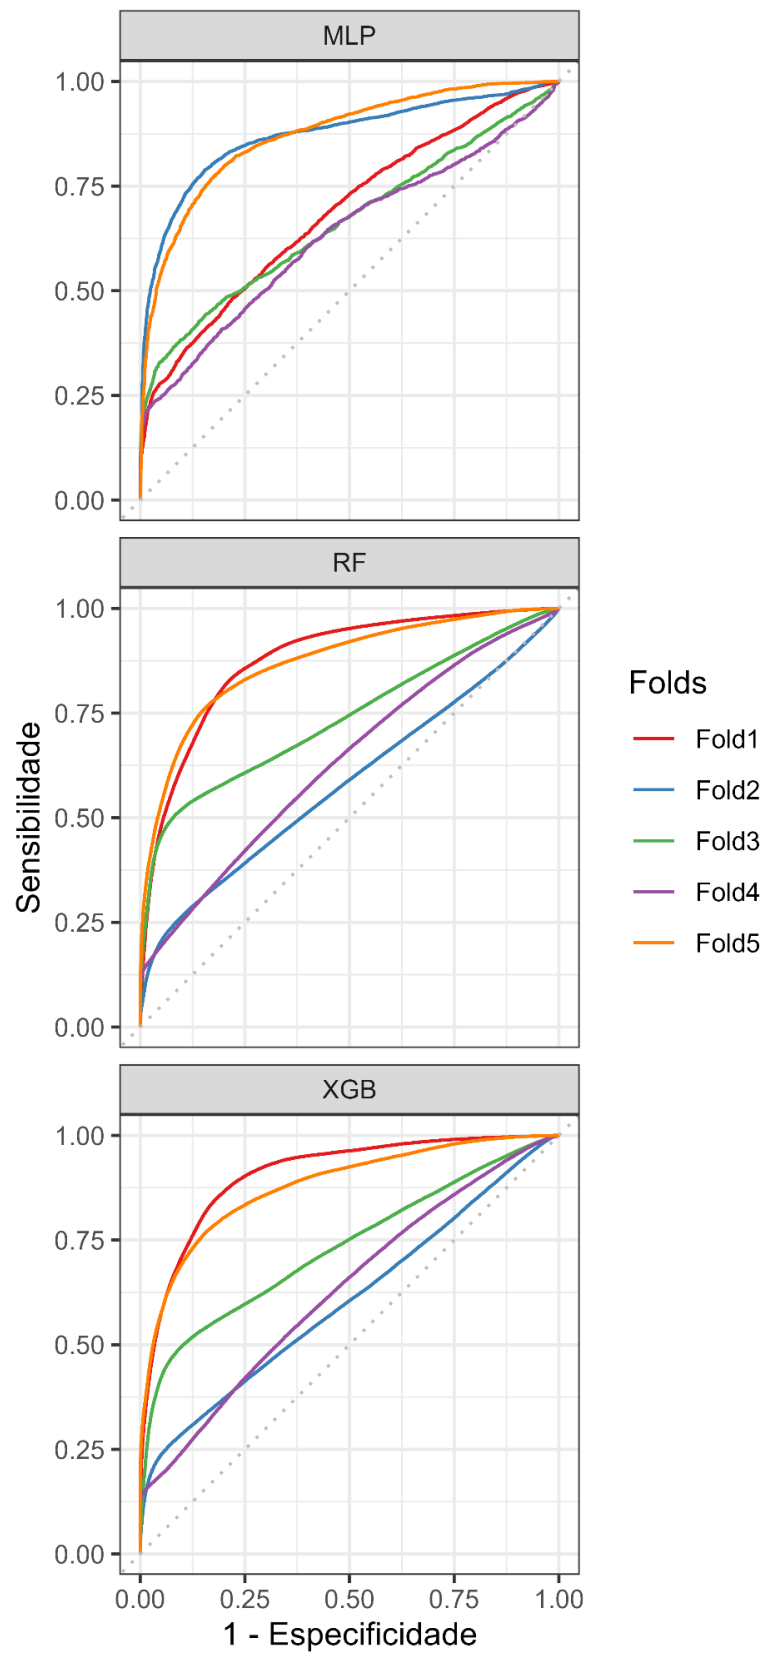


Figura 7 - Curvas ROC para cada modelo e grupo de validação.

Tabela 1 - Valores da área abaixo da curva (AUC) ROC para cada modelo e grupo de validação.

Modelo	Fold	AUROC
MLP	Fold1	0,69
MLP	Fold2	0,87
MLP	Fold3	0,66
MLP	Fold4	0,63
MLP	Fold5	0,87
RF	Fold1	0,88
RF	Fold2	0,58
RF	Fold3	0,74
RF	Fold4	0,63
RF	Fold5	0,87
XGB	Fold1	0,91
XGB	Fold2	0,60
XGB	Fold3	0,73
XGB	Fold4	0,63
XGB	Fold5	0,88

4.2 Avaliação final

A **Tabela 2** apresenta os valores médios das AUC-ROC dos conjuntos de treinamento e teste para os três modelos avaliados, evidenciando uma similaridade de comportamento. Os valores de testes foram superiores aos de treinamento em todos os modelos (**Figura 8**). Essa diferença entre os resultados entre os conjuntos de treinamento e teste se verificam em outros estudos. [De Vasconcelos et al. \(2001\)](#) registrou uma classificação global de 84,1% utilizando o grupo de treino e 73,9% no grupo de validação. O melhor resultado alcançado foi com o conjunto de teste usando o RF. No conjunto de treinamento, todos os modelos obtiveram o mesmo valor de AUC-ROC de 0,75. Em contraposição, no conjunto de teste o modelo RF teve um valor de AUC-ROC de 0,88 pouco superior aos outros dois modelos com 0,84.

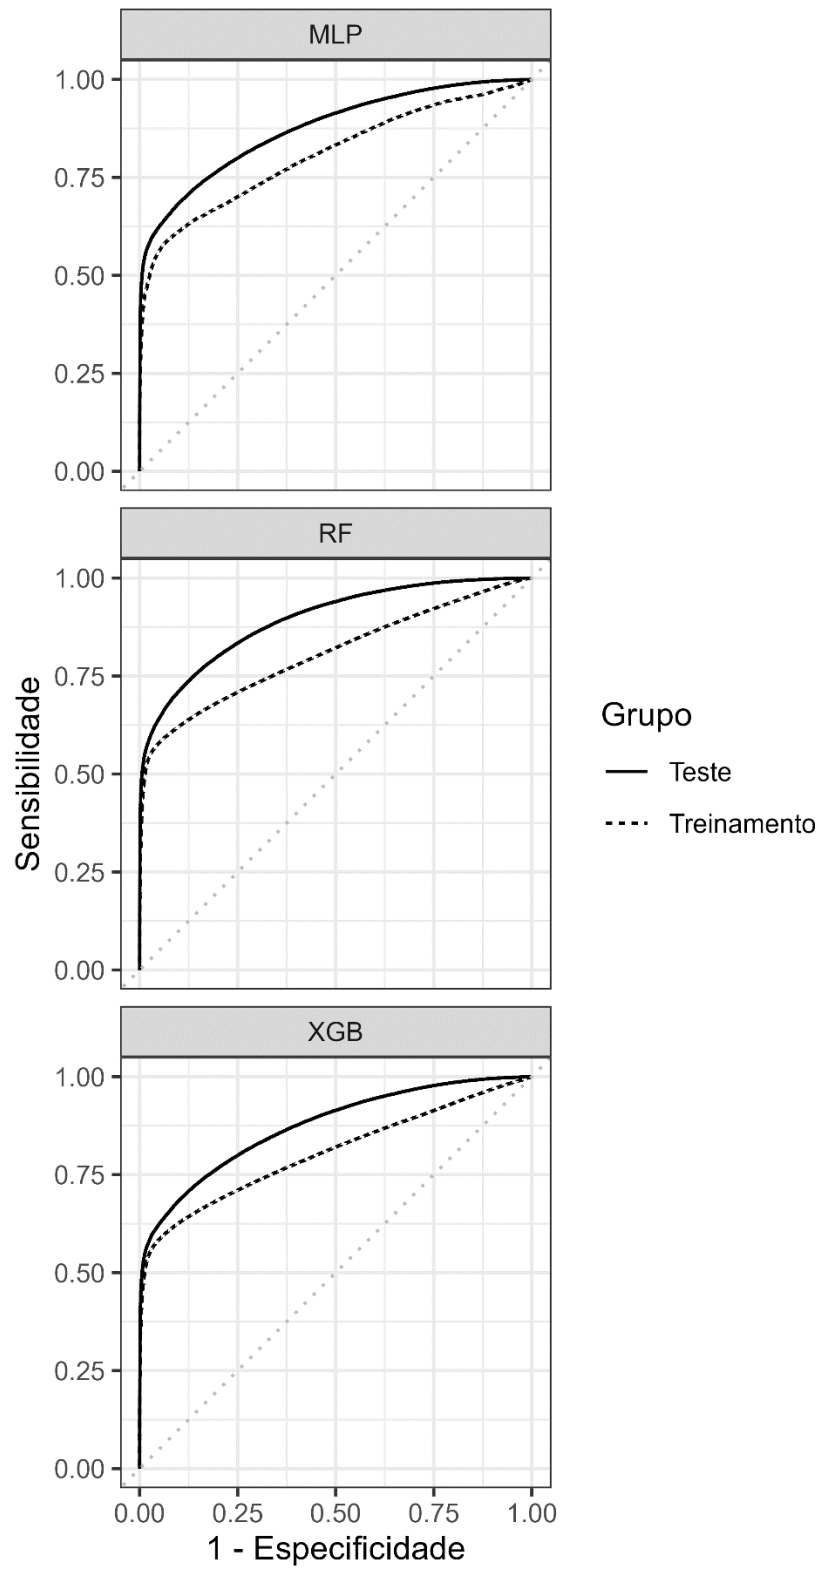


Figura 8 - Curvas ROC médias de treinamento e teste dos modelos.

Tabela 2 - Valores da área abaixo da curva ROC médias de treinamento e teste dos modelos.

Tipo	Modelo	AUROC
Train	MLP	0,75
Train	RF	0,75
Train	XGB	0,75
Test	MLP	0,84
Test	RF	0,88
Test	XGB	0,84

4.3 Mapas de probabilidade

A formulação dos mapas de probabilidade considerou dois cenários: presença das estradas atuais e considerando a efetivação das rodovias planejadas, visando analisar o seu efeito na distribuição de incêndios. A **Figura 9** apresenta os mapas de probabilidade de focos de incêndios referentes aos modelos avaliados considerando o conjunto atual de estradas. Os modelos preditivos usando os métodos baseados em árvores (RF e XGB) tiveram um padrão de distribuição de incêndios similares. A predição do XGB em comparação ao RF apresentou áreas ligeiramente mais propensas a ocorrência de incêndios ao longo das rodovias. Em contraposição, o MLP evidenciou uma probabilidade de incêndios superiores em área e intensidade do que os métodos RF e XGB, cobrindo toda a extensão do arco de desmatamento.

A **Figura 10** demonstra a previsão com a inserção das rodovias planejadas, onde o modelo MLP continua apresentando as áreas mais propensas aos eventos de incêndios de forma mais pronunciada do que os modelos de RF e XGB. Dentre os modelos baseados em árvores, o RF realçou mais os efeitos das novas rodovias do que o XGB. Em contraposição, o modelo MLP evidenciou mais intensivamente as novas estradas pavimentadas.

Objetivando enfatizar o efeito da inserção das estradas pavimentadas, a **Figura 11** mostra a diferença entre os dois cenários (sem e com rodovias planejadas). As imagens das diferenças de probabilidade para os modelos RF e XGB demonstra uma alta homogeneidade e pouco evidência mudanças. Ao contrário, o modelo MLP proporciona destacar com maior intensidade as modificações com o advento das novas rodovias pavimentadas.

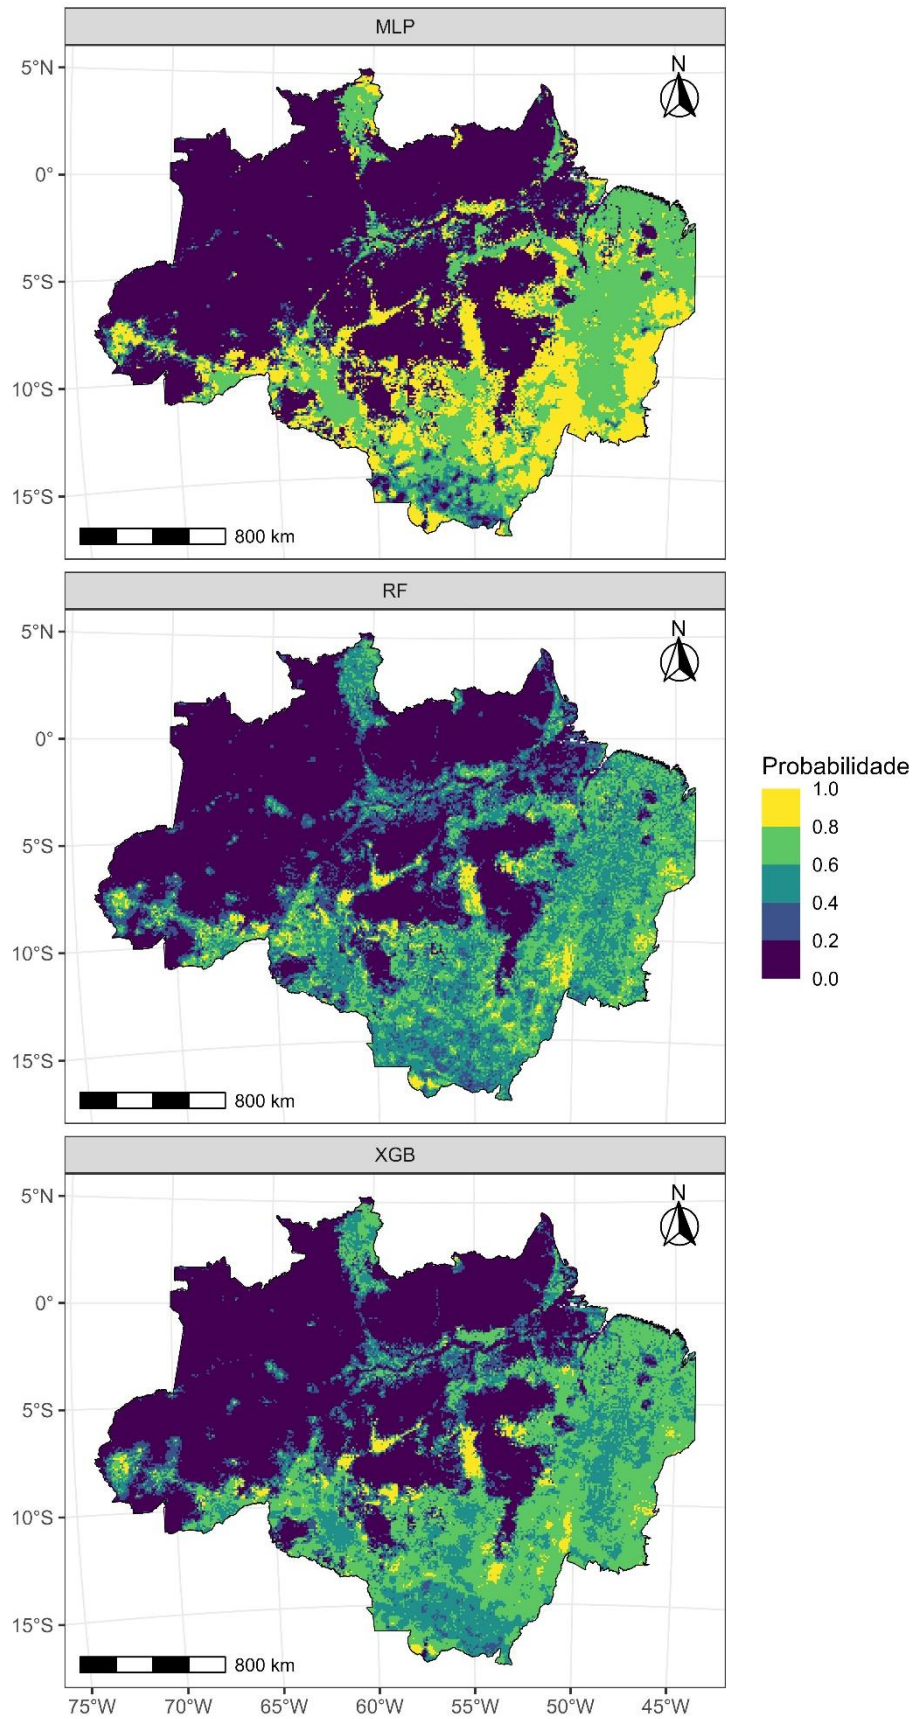


Figura 9 - Mapa de probabilidade de presença de focos segundo os modelos MLP, RF e XGB, considerando as estradas atuais em atividade.

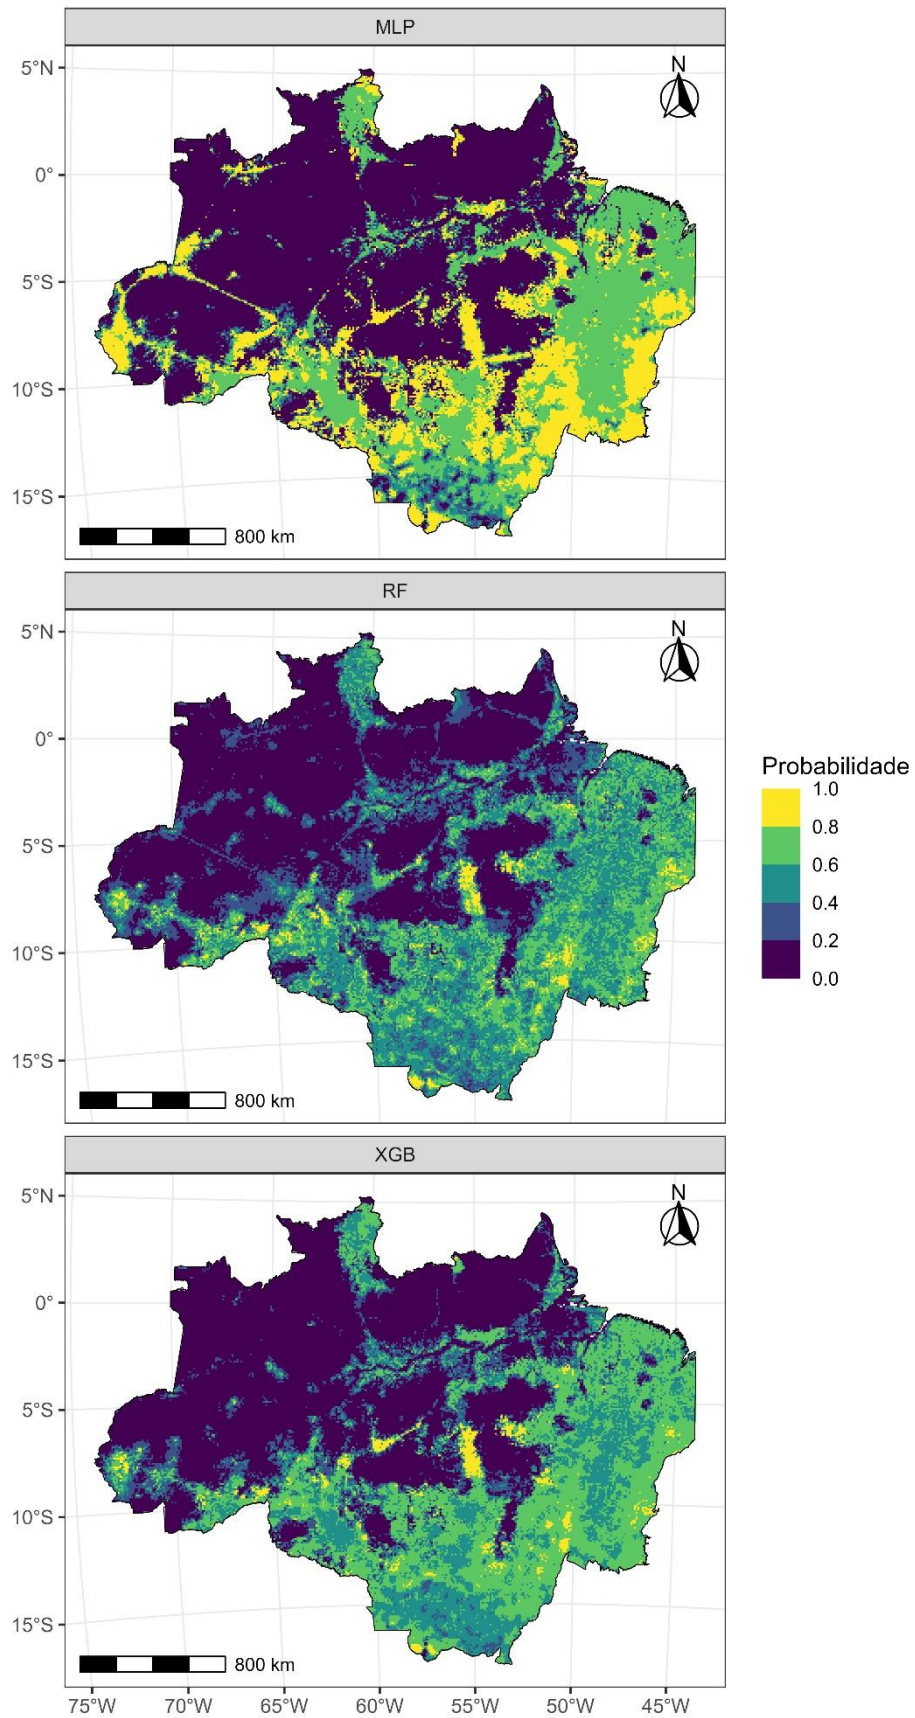


Figura 10 - Mapa de probabilidade de presença de focos dos modelos MLP, RF e XGB com a adição de rodovias planejadas.

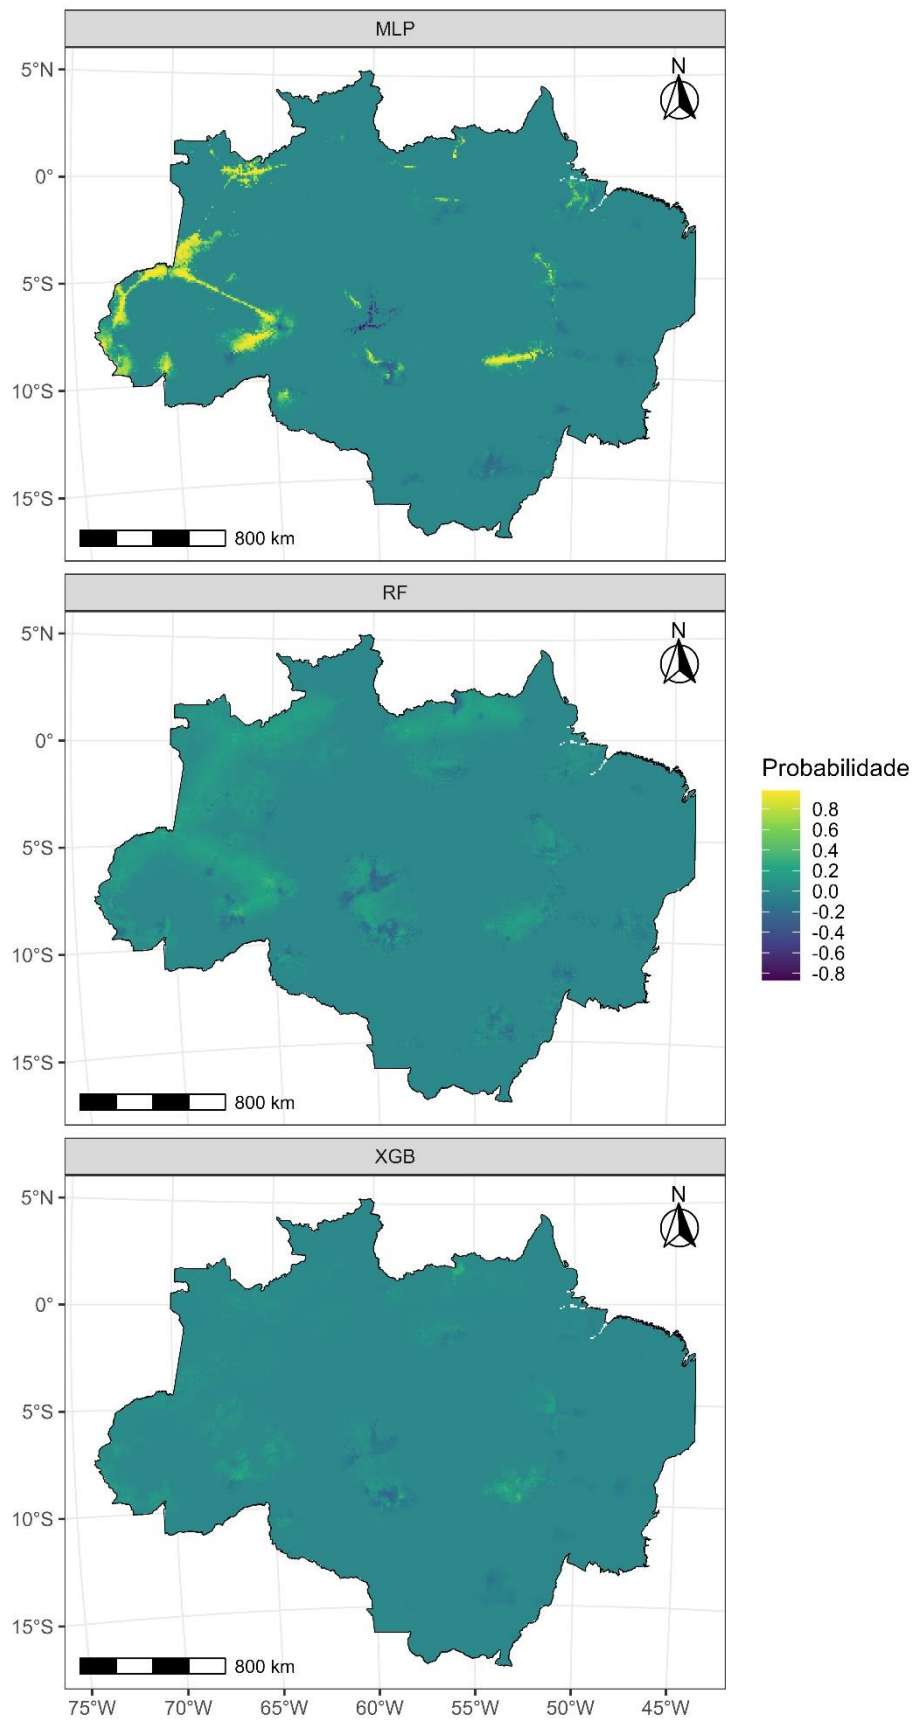


Figura 11 - Mapa de diferença de probabilidades entre os mapas sem e com rodovias planejadas para os modelos MLP, RF e XGB.

5 DISCUSSÃO

Os incêndios florestais consistem em um desafio governamental associados a sistemas socioecológicos complexos que tendem a aumentar no futuro se não forem adotadas medidas governamentais adequadas (Carmenta et al., 2011). Os principais fatores para o aumento de focos de incêndios na região amazônica são as atividades antrópicas, considerando tanto ações propositais como acidentais. Os mapas de probabilidades são importantes por evidenciar os pontos de ignição, para possíveis escape do fogo para a floresta e áreas vizinhas com grandes prejuízos socioeconômicos, ambientais e de saúde da população. A predição de incêndios corrobora na elaboração de melhores estratégias de prevenção (Yang et al., 2007).

Nosso estudo, evidencia que os incêndios possuem uma forte relação com as rodovias, diminuindo a ocorrência com o aumento da distância das estradas em todas as áreas. Esses resultados são bem retratados na literatura. Até o começo da década de 1960, a restrição de acesso à região amazônica favoreceu a preservação florestal. Nos anos subsequentes, projetos de infraestrutura, incluindo estradas federais e estaduais, foram desenvolvidos e associados a programas de incentivos fiscais para assentamento agrário (Fearnside, 2002; Pacheco, 2009). Nesse contexto, as estradas permitiram o acesso humano e promoveram o aumento do desmatamento e do emprego do fogo ao longo de suas margens. Vários autores abordam a influência das estradas como a principal via para o aumento do desmatamento e de incêndios (Fearnside, 2007; Fearnside and De Alencastro Graça, 2006; Fearnside and de Lima Ferreira, 1984; Nepstad et al., 2001; Neto, 2019; Perz et al., 2008; Soares-Filho et al., 2004). Outros países na Bacia Amazônica (Venezuela, Colômbia, Equador e Peru) também apresentam forte influência das estradas nas queimadas, apesar de apresentarem diferenças espaciais no momento do pico de eventos de incêndios (Armenteras et al., 2017). Estudos do começo da década 2000 demonstraram que em uma distância de 100 km das rodovias incluíam 90% das áreas desmatadas (Alves, 2002), e em uma distância de 50 km corresponderia entre 67% (Nepstad et al., 2001) até 85% (Chomitz and Thomas, 2001). No começo da década de 2010, observou-se que uma distância de 5,5 km de estradas ou 1 km de rios, cobrindo 35% da Amazônia Brasileira, apresentavam quase 95% de todo o desmatamento (Barber et al., 2014). Além disso, as áreas desmatadas e florestas perturbadas ou fragmentadas perto de estradas são mais vulneráveis a incêndios. Objetivando coibir o uso de fogo ao longo das rodovias, uma legislação específica foi promulgada para disciplinar o uso de tal prática (Portaria/IBAMA/nº. 231/88, de 08/08/88). Ainda com relação ao uso do fogo, a Lei Federal nº. 4.771 do Código Florestal de 1965 (Artigo 27) regulamenta que é proibido o uso do fogo nas florestas e demais

formas de vegetação (Regulamentado pelo Decreto Federal nº. 2.661, de julho de 1998). O problema é complexo, uma vez que o asfaltamento das estradas não atua somente na viabilização do deslocamento da frente pioneira, mas também estabelece mecanismos e pequenas infraestruturas do governo com propósito de oferecer serviços às populações que já moram nos eixos rodoviários (Neto, 2019).

O aprimoramento da presente pesquisa pode ser obtido com inserção de variáveis desconsideradas na modelagem, tais como as áreas de reservas que possuem importância por limitarem a construção de estradas, desmatamento e incêndios. Na conservação das florestas, o principal mecanismo de proteção são as reservas ambientais de proteção integral, uso limitado e reservas indígenas (Ricketts et al., 2010; Soares-Filho et al., 2010). Portanto, as reservas retêm uma cobertura florestal natural substancial (Ferreira et al., 2005), que consiste em um fator de barreira das ações de fogo dentro e em suas bordas (Arima et al., 2007), mesmo considerando regiões de contorno altamente afetadas (Fearnside, 2003; Nepstad et al., 2006). No entanto, a presença das reservas não coíbe ações de danos ambientais, tais como a caça (Antunes et al., 2019; Carvalho, 2019; Peres and Zimmerman, 2001) e o seu tamanho pode ser insuficiente para manter as populações de muitas espécies. Além disso, as áreas próximas a rodovias e rios em áreas protegidas apresentam menor desmatamento (10,9%) do que áreas desprotegidas (43,6%) (Barber et al., 2014). No entanto, alguns estudos demonstram vulnerabilidades das reservas para a contenção de incêndios que saem do controle por agricultores, evidenciando as fragilidades das políticas de manejo do fogo e suas ameaças para a conservação da floresta (Carmenta et al., 2019). Categorias de reserva que envolve terras de particulares também possui maior suscetibilidade, por exemplo, o conjunto de unidades de Conservação na região da Terra do Meio possui uma eficiente conservação dos ecossistemas naturais e inibição da ocorrência de incêndios, com exceção da Área de Proteção Ambiental Triunfo do Xingu por envolver terras de particulares (Jesus and Catojo, 2020).

Além da inserção das áreas de reservas, outros fatores políticos e econômicos podem condicionar os eventos de incêndios e podem ser alvo de novos estudos, incluindo outros projetos de infraestrutura, preços da carne bovina e da soja, e variações climáticas interanuais com presença de anos mais secos.

6 CONCLUSÃO

Este estudo analisou modelos de aprendizado de máquina, incluindo Random Forest (RF), Extreme Gradient Boost (XGB) e Multilayer Perceptron (MLP), para prever as áreas mais vulneráveis a incêndios na região da Floresta Amazônica brasileira. A variável dependente foi

o conjunto de eventos de incêndios extraídos do BDQueimadas para o ano de 2021 e as variáveis independentes foram constituídas pelos seguintes fatores: (a) distância das cidades considerando três categorias (grandes, médios e pequenos centros urbanos), (b) distância da malha rodoviária subdivididas em três categorias (primária, secundária e terciária), e (c) fatores climáticos referentes a temperatura média da superfície terrestre e precipitação média observadas no ano de 2021. Além disso, a pesquisa considerou dois cenários: (a) contendo a malha rodoviária atual, e (b) acrescentando as estradas planejadas. A precisão dos modelos foi avaliada usando a curva Receiver Operating Characteristic (ROC) e comparada com dados reais de incêndio. Os resultados mostraram que o Random Forest obteve o melhor valor de AUC de 0,88, seguido de MLP e XGB com valores de AUC de 0,84. Entretanto, o modelo MLP considerando a expansão da malha rodoviária permitiu melhor evidenciar as alterações dos eventos de fogos ao longo das novas rodovias. O estudo constatou que a interferência de novas rodovias é um fator significativo na indução de incêndios. Por fim, pesquisas futuras podem ser desenvolvidas incorporando mais variáveis ambientais e antropogênicas e comparando-as com outros métodos de inteligência artificial.

7 REFERÊNCIAS

- Adab, H., 2017. Landfire hazard assessment in the Caspian Hyrcanian forest ecoregion with the long-term MODIS active fire data. *Nat. Hazards* 87, 1807–1825. <https://doi.org/10.1007/s11069-017-2850-2>
- Alves, D.S., 2002. Space-time dynamics of deforestation in Brazilian Amazônia. *Int. J. Remote Sens.* 23, 2903–2908. <https://doi.org/10.1080/01431160110096791>
- Amatulli, G., Camia, A., San-Miguel-Ayanz, J., 2013. Estimating future burned areas under changing climate in the EU-Mediterranean countries. *Sci. Total Environ.* 450–451, 209–222. <https://doi.org/10.1016/j.scitotenv.2013.02.014>
- Antunes, A.P., Rebêlo, G.H., Pezzuti, J.C.B., Vieira, M.A.R. de M., Constantino, P. de A.L., Campos-Silva, J.V., Fonseca, R., Durigan, C.C., Ramos, R.M., Amaral, J.V. do, Camps Pimenta, N., Ranzi, T.J.D., Lima, N.A.S., Shepard, G.H., 2019. A conspiracy of silence: Subsistence hunting rights in the Brazilian Amazon. *Land use policy* 84, 1–11. <https://doi.org/10.1016/j.landusepol.2019.02.045>
- Aragão, L.E.O.C., Shimabukuro, Y.E., 2010. The Incidence of Fire in Amazonian Forests with Implications for REDD. *Science* (80-.). 328, 1275–1278. <https://doi.org/10.1126/science.1186925>
- Arima, E.Y., Simmons, C.S., Walker, R.T., Cochrane, M.A., 2007. Fire in the Brazilian Amazon: A spatially explicit model for policy impact analysis. *J. Reg. Sci.* 47, 541–567. <https://doi.org/10.1111/j.1467-9787.2007.00519.x>
- Armenteras, D., Barreto, J.S., Tabor, K., Molowny-Horas, R., Retana, J., 2017. Changing patterns of fire occurrence in proximity to forest edges, roads and rivers between NW Amazonian countries. *Biogeosciences* 14, 2755–2765. <https://doi.org/10.5194/bg-14-2755-2017>
- Arvor, D., Daugeard, M., Tritsch, I., De Mello-Thery, N.A., Thery, H., Dubreuil, V., 2018. Combining socioeconomic development with environmental governance in the Brazilian Amazon: the Mato Grosso agricultural frontier at a tipping point. *Environ. Dev. Sustain.* 20, 1–22. <https://doi.org/10.1007/s10668-016-9889-1>

- Balch, J.K., Brando, P.M., Nepstad, D.C., Coe, M.T., Silvério, D., Massad, T.J., Davidson, E.A., Lefebvre, P., Oliveira-Santos, C., Rocha, W., Cury, R.T.S., Parsons, A., Carvalho, K.S., 2015. The Susceptibility of Southeastern Amazon Forests to Fire: Insights from a Large-Scale Burn Experiment. *Bioscience* 65, 893–905. <https://doi.org/10.1093/biosci/biv106>
- Barber, C.P., Cochrane, M.A., Souza, C.M., Laurance, W.F., 2014. Roads, deforestation, and the mitigating effect of protected areas in the Amazon. *Biol. Conserv.* 177, 203–209. <https://doi.org/10.1016/j.biocon.2014.07.004>
- Barlow, J., Lennox, G.D., Ferreira, J., Berenguer, E., Lees, A.C., Nally, R. Mac, Thomson, J.R., Ferraz, S.F.D.B., Louzada, J., Oliveira, V.H.F., Parry, L., Ribeiro De Castro Solar, R., Vieira, I.C.G., Aragaõ, L.E.O.C., Begotti, R.A., Braga, R.F., Cardoso, T.M., Jr, R.C.D.O., Souza, C.M., Moura, N.G., Nunes, S.S., Siqueira, J.V., Pardini, R., Silveira, J.M., Vaz-De-Mello, F.Z., Veiga, R.C.S., Venturieri, A., Gardner, T.A., 2016. Anthropogenic disturbance in tropical forests can double biodiversity loss from deforestation. *Nature* 535, 144–147. <https://doi.org/10.1038/nature18326>
- Baum, E.B., 1988. On the capabilities of multilayer perceptrons. *J. Complex.* 4, 193–215. [https://doi.org/10.1016/0885-064X\(88\)90020-9](https://doi.org/10.1016/0885-064X(88)90020-9)
- Bertolotto, M., McArdle, G., Schoen-Phelan, B., 2020. Volunteered and crowdsourced geographic information: the OpenStreetMap project. *J. Spat. Inf. Sci.* 20, 65–70. <https://doi.org/10.5311/JOSIS.2020.20.659>
- Boubeta, M., Lombardía, M.J., Marey-Pérez, M.F., Morales, D., 2015. Prediction of forest fires occurrences with area-level Poisson mixed models. *J. Environ. Manage.* 154, 151–158. <https://doi.org/10.1016/j.jenvman.2015.02.009>
- Bowman, D.M.J.S., Balch, J.K., Artaxo, P., Bond, W.J., Carlson, J.M., Cochrane, M.A., D’Antonio, C.M., DeFries, R.S., Doyle, J.C., Harrison, S.P., Johnston, F.H., Keeley, J.E., Krawchuk, M.A., Kull, C.A., Marston, J.B., Moritz, M.A., Prentice, I.C., Roos, C.I., Scott, A.C., Swetnam, T.W., van der Werf, G.R., Pyne, S.J., 2009. Fire in the Earth System. *Science* (80-). 324, 481–484. <https://doi.org/10.1126/science.1163886>
- Brasil, 1953. Lei nº 1.806, de 6 de janeiro de 1953 1–3.
- Breiman, L., 2001. Random Forests. *Mach. Learn.* 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Broadbent, E.N., Asner, G.P., Keller, M., Knapp, D.E., Oliveira, P.J.C., Silva, J.N., 2008. Forest fragmentation and edge effects from deforestation and selective logging in the Brazilian Amazon. *Biol. Conserv.* 141, 1745–1757. <https://doi.org/10.1016/j.biocon.2008.04.024>
- Butt, E.W., Conibear, L., Reddington, C.L., Darbyshire, E., Morgan, W.T., Coe, H., Artaxo, P., Brito, J., Knote, C., Spracklen, D. V., 2020. Large air quality and human health impacts due to Amazon forest and vegetation fires. *Environ. Res. Commun.* 2, 095001. <https://doi.org/10.1088/2515-7620/abb0db>
- Cabral, A.L.A., Moras Filho, L.O., Borges, L.A.C., 2013. Uso do fogo na agricultura: legislação, impactos ambientais e realidade na Amazônia. *Periódico Eletrônico Fórum Ambient. da Alta Paul.* 9, 159–172. <https://doi.org/10.17271/19800827952013577>
- Carmenta, R., Coudel, E., Steward, A.M., 2019. Forbidden fire: Does criminalising fire hinder conservation efforts in swidden landscapes of the Brazilian Amazon? *Geogr. J.* 185, 23–37. <https://doi.org/10.1111/geoj.12255>
- Carmenta, R., Parry, L., Blackburn, A., Vermeylen, S., Barlow, J., Carmenta, R., Parry, L., Blackburn, A., Vermeylen, S., Barlow, J., 2011. Understanding Human-Fire Interactions in Tropical Forest Regions : a Case for Interdisciplinary Research across the Natural and Social. *Ecol. Soc.* 16, 22.
- Carvalho, E.A., 2019. Jaguar hunting in Amazonian extractive reserves: acceptance and prevalence. *Environ. Conserv.* 46, 334–339. <https://doi.org/10.1017/S0376892919000274>
- Cavalcante, R.B.L., Pontes, P.R.M., Souza-Filho, P.W.M., de Souza, E.B., 2019. Opposite Effects of Climate and Land Use Changes on the Annual Water Balance in the Amazon Arc of Deforestation. *Water Resour. Res.* 55, 3092–3106. <https://doi.org/10.1029/2019WR025083>

- Chang, Y., Zhu, Z., Bu, R., Chen, H., Feng, Y., Li, Y., Hu, Y., Wang, Z., 2013. Predicting fire occurrence patterns with logistic regression in Heilongjiang Province, China. *Landsc. Ecol.* 28, 1989–2004. <https://doi.org/10.1007/s10980-013-9935-4>
- Chen, T., He, T., 2014. *xgboost: Extreme Gradient Boosting*. R Lect. 1–84.
- Chomitz, K.M., Thomas, T.S., 2001. *Geographic Patterns of Land Use and Land Intensity in the Brazilian Amazon*. World Bank, Washington, DC.
- Christian, H.J., Blakeslee, R.J., Boccippio, D.J., Boeck, W.L., Buechler, D.E., Driscoll, K.T., Goodman, S.J., Hall, J.M., Koshak, W.J., Mach, D.M., Stewart, M.F., 2003. Global frequency and distribution of lightning as observed from space by the Optical Transient Detector. *J. Geophys. Res. Atmos.* 108. <https://doi.org/10.1029/2002jd002347>
- Cipriani, H.N., Pereira, J.A.A., Silva, R.A., Freitas, S.G. de, Oliveira, L.T. de, 2011. Fire risk map for the Serra de São Domingos Municipal Park, Poços de Caldas, MG. *CERNE* 17, 77–83. <https://doi.org/10.1590/S0104-77602011000100009>
- Cochrane, M.A., Laurance, W.F., 2008. Synergisms among fire, land use, and climate change in the Amazon. *Ambio* 37, 522–527. <https://doi.org/10.1579/0044-7447-37.7.522>
- Cochrane, M.A., Laurance, W.F., 2002. Fire as a large-scale edge effect in Amazonian forests. *J. Trop. Ecol.* 18, 311–325. <https://doi.org/10.1017/S0266467402002237>
- Costa, M.H., Foley, J.A., 1997. Water balance of the Amazon Basin: Dependence on vegetation cover and canopy conductance. *J. Geophys. Res. Atmos.* 102, 23973–23989. <https://doi.org/10.1029/97jd01865>
- de Bem, P.P., de Carvalho Júnior, O.A., Matricardi, E.A.T., Guimarães, R.F., Gomes, R.A.T., 2019. Predicting wildfire vulnerability using logistic regression and artificial neural networks: a case study in Brazil's Federal District. *Int. J. Wildl. Fire* 28, 35. <https://doi.org/10.1071/WF18018>
- de Mendonça, M.J.C., Vera Diaz, M. del C., Nepstad, D., Seroa da Motta, R., Alencar, A., Gomes, J.C., Ortiz, R.A., 2004. The economic cost of the use of fire in the Amazon. *Ecol. Econ.* 49, 89–105. <https://doi.org/10.1016/j.ecolecon.2003.11.011>
- de Vasconcellos, A.C.S., Hallwass, G., Bezerra, J.G., Aciole, A.N.S., Meneses, H.N. de M., Lima, M. de O., de Jesus, I.M., Hacon, S. de S., Basta, P.C., 2021. Health risk assessment of mercury exposure from fish consumption in munduruku indigenous communities in the brazilian amazon. *Int. J. Environ. Res. Public Health* 18. <https://doi.org/10.3390/ijerph18157940>
- De Vasconcelos, M.J.P., Silva, S., Tomé, M., Alvim, M., Pereira, J.M.C., 2001. Spatial prediction of fire ignition probabilities: Comparing logistic regression and neural networks. *Photogramm. Eng. Remote Sensing* 67, 73–81.
- Eskandari, S., Chuvieco, E., 2015. Fire danger assessment in Iran based on geospatial information. *Int. J. Appl. Earth Obs. Geoinf.* 42, 57–64. <https://doi.org/10.1016/j.jag.2015.05.006>
- Eugenio, F.C., dos Santos, A.R., Fiedler, N.C., Ribeiro, G.A., da Silva, A.G., dos Santos, Á.B., Paneto, G.G., Schettino, V.R., 2016. Applying GIS to develop a model for forest fire risk: A case study in Espírito Santo, Brazil. *J. Environ. Manage.* 173, 65–71. <https://doi.org/10.1016/j.jenvman.2016.02.021>
- Faraggi, D., Reiser, B., 2002. Estimation of the area under the ROC curve. *Stat. Med.* 21, 3093–3106. <https://doi.org/10.1002/sim.1228>
- Fearnside, P.M., 2007. Brazil's Cuiabá- Santarém (BR-163) Highway: The environmental cost of paving a soybean corridor through the Amazon. *Environ. Manage.* 39, 601–614. <https://doi.org/10.1007/s00267-006-0149-2>
- Fearnside, P.M., 2006. Desmatamento na Amazônia: dinâmica, impactos e controle. *Acta Amaz.* 36, 395–400. <https://doi.org/10.1590/S0044-59672006000300018>
- Fearnside, P.M., 2003. Conservation policy in Brazilian Amazonia: Understanding the Dilemmas. *World Dev.* 31, 757–779. [https://doi.org/10.1016/S0305-750X\(03\)00011-1](https://doi.org/10.1016/S0305-750X(03)00011-1)

- Fearnside, P.M., 2002. Avanço Brasil: Environmental and Social Consequences of Brazil's Planned Infrastructure in Amazonia. *Environ. Manage.* 30, 735–747. <https://doi.org/10.1007/s00267-002-2788-2>
- Fearnside, P.M., De Alencastro Graça, P.M.L., 2006. BR-319: Brazil's Manaus-Porto Velho Highway and the potential impact of linking the Arc of Deforestation to Central Amazonia. *Environ. Manage.* 38, 705–716. <https://doi.org/10.1007/s00267-005-0295-y>
- Fearnside, P.M., de Lima Ferreira, G., 1984. Roads in Rondônia: Highway Construction and the Farce of Unprotected Reserves in Brazil's Amazonian Forest. *Environ. Conserv.* 11, 358–360. <https://doi.org/10.1017/S0376892900014740>
- Feng, X., Merow, C., Liu, Z., Park, D.S., Roehrdanz, P.R., Maitner, B., Newman, E.A., Boyle, B.L., Lien, A., Burger, J.R., Pires, M.M., Brando, P.M., Bush, M.B., McMichael, C.N.H., Neves, D.M., Nikolopoulos, E.I., Saleska, S.R., Hannah, L., Breshears, D.D., Evans, T.P., Soto, J.R., Ernst, K.C., Enquist, B.J., 2021. How deregulation, drought and increasing fire impact Amazonian biodiversity. *Nature* 597, 516–521. <https://doi.org/10.1038/s41586-021-03876-7>
- Ferreira, A.M.M., Salati, E., 2005. Forças de transformação do ecossistema amazônico. *Estud. Avançados* 19, 25–44. <https://doi.org/10.1590/S0103-40142005000200003>
- Ferreira, L.V., Venticinque, E., Almeida, S., 2005. O desmatamento na Amazônia e a importância das áreas protegidas. *Estud. Avançados* 19, 157–166. <https://doi.org/10.1590/S0103-40142005000100010>
- Fisch, G., Marengo, J.A., Nobre, C.A., 1998. Uma Revisão Geral sobre o Clima da Amazônia. *Acta Amazônica. Acta Amaz.* 28, 101–126.
- Fonte, C.C., Bastin, L., See, L., Foody, G., Lupia, F., 2015. Usability of VGI for validation of land cover maps. *Int. J. Geogr. Inf. Sci.* 29, 1269–1291. <https://doi.org/10.1080/13658816.2015.1018266>
- Franco-Moraes, J., Clement, C.R., Cabral de Oliveira, J., Oliveira, A.A. de, 2021. A framework for identifying and integrating sociocultural and environmental elements of indigenous peoples' and local communities' landscape transformations. *Perspect. Ecol. Conserv.* 19, 143–152. <https://doi.org/10.1016/j.pecon.2021.02.008>
- Franklin, S.L., Pindyck, R.S., 2018. Tropical Forests, Tipping Points, and the Social Cost of Deforestation. *Ecol. Econ.* 153, 161–171. <https://doi.org/10.1016/j.ecolecon.2018.06.003>
- Fu, R., Yin, L., Li, W., Arias, P.A., Dickinson, R.E., Huang, L., Chakraborty, S., Fernandes, K., Liebmann, B., Fisher, R., Myneni, R.B., 2013. Increased dry-season length over southern Amazonia in recent decades and its implication for future climate projection. *Proc. Natl. Acad. Sci.* 110, 18110–18115. <https://doi.org/10.1073/pnas.1302584110>
- Gatti, L. V., Basso, L.S., Miller, J.B., Gloor, M., Gatti Domingues, L., Cassol, H.L.G., Tejada, G., Aragão, L.E.O.C., Nobre, C., Peters, W., Marani, L., Arai, E., Sanches, A.H., Corrêa, S.M., Anderson, L., Von Randow, C., Correia, C.S.C., Crispim, S.P., Neves, R.A.L., 2021. Amazonia as a carbon source linked to deforestation and climate change. *Nature* 595, 388–393. <https://doi.org/10.1038/s41586-021-03629-6>
- Genuer, R., Poggi, J.M., Tuleau-Malot, C., 2010. Variable selection using random forests. *Pattern Recognit. Lett.* 31, 2225–2236. <https://doi.org/10.1016/j.patrec.2010.03.014>
- Ghorbanzadeh, O., Valizadeh Kamran, K., Blaschke, T., Aryal, J., Naboureh, A., Einali, J., Bian, J., 2019. Spatial Prediction of Wildfire Susceptibility Using Field Survey GPS Data and Machine Learning Approaches. *Fire* 2, 43. <https://doi.org/10.3390/fire2030043>
- Goldarag, Y.J., Mohammadzadeh, A., Ardakani, A.S., 2016. Fire Risk Assessment Using Neural Network and Logistic Regression. *J. Indian Soc. Remote Sens.* 44, 885–894. <https://doi.org/10.1007/s12524-016-0557-6>
- Goldblatt, R., Jones, N., Mannix, J., 2020. Assessing OpenStreetMap Completeness for Management of Natural Disaster by Means of Remote Sensing: A Case Study of Three Small Island States (Haiti, Dominica and St. Lucia). *Remote Sens.* 12, 118. <https://doi.org/10.3390/rs12010118>
- Gonçalves, K. dos S., Castro, H., Hacon, S. de S., 2012. As queimadas na região amazônica e o adoecimento

- respiratório. *Cien. Saude Colet.* 17, 1523–1532. <https://doi.org/10.1590/S1413-81232012000600016>
- Graff, C.A., Coffield, S.R., Chen, Y., Foufoula-Georgiou, E., Randerson, J.T., Smyth, P., 2020. Forecasting Daily Wildfire Activity Using Poisson Regression. *IEEE Trans. Geosci. Remote Sens.* 58, 4837–4851. <https://doi.org/10.1109/TGRS.2020.2968029>
- Grinberger, A.Y., Minghini, M., Yeboah, G., Juhász, L., Mooney, P., 2022. Bridges and Barriers: An Exploration of Engagements of the Research Community with the OpenStreetMap Community. *ISPRS Int. J. Geo-Information* 11. <https://doi.org/10.3390/ijgi11010054>
- Guo, F., Su, Z., Wang, G., Sun, L., Lin, F., Liu, A., 2016a. Wildfire ignition in the forests of southeast China: Identifying drivers and spatial distribution to predict wildfire likelihood. *Appl. Geogr.* 66, 12–21. <https://doi.org/10.1016/j.apgeog.2015.11.014>
- Guo, F., Wang, G., Su, Z., Liang, H., Wang, W., Lin, F., Liu, A., 2016b. What drives forest fire in Fujian, China? Evidence from logistic regression and Random Forests. *Int. J. Wildl. Fire* 25, 505. <https://doi.org/10.1071/WF15121>
- Herfort, B., Lautenbach, S., Porto de Albuquerque, J., Anderson, J., Zipf, A., 2021. The evolution of humanitarian mapping within the OpenStreetMap community. *Sci. Rep.* 11, 1–15. <https://doi.org/10.1038/s41598-021-82404-z>
- Jaafari, A., Pourghasemi, H.R., 2019. Factors Influencing Regional-Scale Wildfire Probability in Iran, in: *Spatial Modeling in GIS and R for Earth and Environmental Sciences*. Elsevier, pp. 607–619. <https://doi.org/10.1016/B978-0-12-815226-3.00028-4>
- Jesus, S.C. de, Catojo, A.M.Z., 2020. Deforestation in Conservation Units of the Brazilian Amazon: the case of the Terra do Meio Mosaic. *Ciência e Nat.* 42, e42. <https://doi.org/10.5902/2179460x41390>
- Jung, J., Kim, C., Jayakumar, S., Kim, S., Han, S., Kim, D.H., Heo, J., 2013. Forest fire risk mapping of Kolli Hills, India, considering subjectivity and inconsistency issues. *Nat. Hazards* 65, 2129–2146. <https://doi.org/10.1007/s11069-012-0465-1>
- Kayet, N., Chakrabarty, A., Pathak, K., Sahoo, S., Dutta, T., Hatai, B.K., 2020. Comparative analysis of multi-criteria probabilistic FR and AHP models for forest fire risk (FFR) mapping in Melghat Tiger Reserve (MTR) forest. *J. For. Res.* 31, 565–579. <https://doi.org/10.1007/s11676-018-0826-z>
- Kumari, B., Pandey, A.C., 2020. Geo-informatics based multi-criteria decision analysis (MCDA) through analytic hierarchy process (AHP) for forest fire risk mapping in Palamau Tiger Reserve, Jharkhand state, India. *J. Earth Syst. Sci.* 129, 204. <https://doi.org/10.1007/s12040-020-01461-6>
- Laurance, W.F., Lovejoy, T.E., Vasconcelos, H.L., Bruna, E.M., Didham, R.K., Stouffer, P.C., Gascon, C., Bierregaard, R.O., Laurance, S.G., Sampaio, E., 2002. Ecosystem Decay of Amazonian Forest Fragments: a 22-Year Investigation. *Conserv. Biol.* 16, 605–618. <https://doi.org/10.1046/j.1523-1739.2002.01025.x>
- Lima, A., Silva, T.S.F., Aragão, L.E.O. e C. de, Feitas, R.M. de, Adami, M., Formaggio, A.R., Shimabukuro, Y.E., 2012. Land use and land cover changes determine the spatial relationship between fire and deforestation in the Brazilian Amazon. *Appl. Geogr.* 34, 239–246. <https://doi.org/10.1016/j.apgeog.2011.10.013>
- Lima, M.G.B., Haring, N., Jagers, S.C., Löfgren, Å., Persson, U.M., Sjöstedt, M., Brülde, B., Langlet, D., Steffen, W., Alpizar, F., 2021. Large-scale collective action to avoid an Amazon tipping point - key actors and interventions. *Curr. Res. Environ. Sustain.* 3, 100048. <https://doi.org/10.1016/j.crsust.2021.100048>
- Lopes, T.R., Zolin, C.A., Mingoti, R., Vendrusculo, L.G., Almeida, F.T. de, Souza, A.P. de, Oliveira, R.F. de, Paulino, J., Uliana, E.M., 2021. Hydrological regime, water availability and land use/land cover change impact on the water balance in a large agriculture basin in the Southern Brazilian Amazon. *J. South Am. Earth Sci.* 108. <https://doi.org/10.1016/j.jsames.2021.103224>
- Lovejoy, T.E., Nobre, C., 2019. Amazon tipping point: Last chance for action. *Sci. Adv.* 5. <https://doi.org/10.1126/sciadv.aba2949>

- Ma, W., Feng, Z., Cheng, Z., Chen, S., Wang, F., 2020. Identifying Forest Fire Driving Factors and Related Impacts in China Using Random Forest Algorithm. *Forests* 11, 507. <https://doi.org/10.3390/f11050507>
- Malhi, Y., Roberts, J.T., Betts, R.A., Killeen, T.J., Li, W., Nobre, C.A., 2008. Climate Change, Deforestation, and the Fate of the Amazon. *Science* (80-.). 319, 169–172. <https://doi.org/10.1126/science.1146961>
- Maranhão, R.L.A., de Carvalho Júnior, O.A., Hermuche, P.M., Gomes, R.A.T., McManus Pimentel, C.M., Guimarães, R.F., 2019. The Spatiotemporal Dynamics of Soybean and Cattle Production in Brazil. *Sustainability* 11, 2150. <https://doi.org/10.3390/su11072150>
- Marzban, C., 2004. The ROC Curve and the Area under It as Performance Measures. *Weather Forecast.* 19, 1106–1114. <https://doi.org/10.1175/825.1>
- Mello, N.G.R. de, Artaxo, P., 2017. Evolução do Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal. *Rev. do Inst. Estud. Bras.* 108. <https://doi.org/10.11606/issn.2316-901x.v0i66p108-129>
- Milanović, S.D.S., Marković, N., Pamučar, D., Gigović, L., Kostić, P., Milanović, S.D.S., 2020. Forest Fire Probability Mapping in Eastern Serbia: Logistic Regression versus Random Forest Method. *Forests* 12, 5. <https://doi.org/10.3390/f12010005>
- Mohajane, M., Costache, R., Karimi, F., Bao Pham, Q., Essahlaoui, A., Nguyen, H., Laneve, G., Oudija, F., 2021. Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. *Ecol. Indic.* 129, 107869. <https://doi.org/10.1016/j.ecolind.2021.107869>
- Mohammadi, F., Bavaghar, M.P., Shabaniyan, N., 2014. Forest Fire Risk Zone Modeling Using Logistic Regression and GIS: An Iranian Case Study. *Small-scale For.* 13, 117–125. <https://doi.org/10.1007/s11842-013-9244-4>
- Monjarás-Vega, N.A., Briones-Herrera, C.I., Vega-Nieva, D.J., Calleros-Flores, E., Corral-Rivas, J.J., López-Serrano, P.M., Pompa-García, M., Rodríguez-Trejo, D.A., Carrillo-Parra, A., González-Cabán, A., Alvarado-Celestino, E., Jolly, W.M., 2020. Predicting forest fire kernel density at multiple scales with geographically weighted regression in Mexico. *Sci. Total Environ.* 718, 137313. <https://doi.org/10.1016/j.scitotenv.2020.137313>
- Morello, T.F., Parry, L., Markusson, N., Barlow, J., 2017. Policy instruments to control Amazon fires: A simulation approach. *Ecol. Econ.* 138, 199–222. <https://doi.org/10.1016/j.ecolecon.2017.03.043>
- Morton, D.C., Le Page, Y., DeFries, R., Collatz, G.J., Hurtt, G.C., 2013. Understorey fire frequency and the fate of burned forests in southern Amazonia. *Philos. Trans. R. Soc. B Biol. Sci.* 368. <https://doi.org/10.1098/rstb.2012.0163>
- Murtagh, F., 1991. Multilayer perceptrons for classification and regression. *Neurocomputing* 2, 183–197. [https://doi.org/10.1016/0925-2312\(91\)90023-5](https://doi.org/10.1016/0925-2312(91)90023-5)
- Neis, P., 2015. Measuring the Reliability of Wheelchair User Route Planning based on Volunteered Geographic Information. *Trans. GIS* 19, 188–201. <https://doi.org/10.1111/tgis.12087>
- Neis, P., Zielstra, D., 2014. Recent Developments and Future Trends in Volunteered Geographic Information Research: The Case of OpenStreetMap. *Futur. Internet* 6, 76–106. <https://doi.org/10.3390/fi6010076>
- Nepstad, D., Carvalho, G., Cristina Barros, A., Alencar, A., Paulo Capobianco, J., Bishop, J., Moutinho, P., Lefebvre, P., Lopes Silva, U., Prins, E., 2001. Road paving, fire regime feedbacks, and the future of Amazon forests. *For. Ecol. Manage.* 154, 395–407. [https://doi.org/10.1016/S0378-1127\(01\)00511-4](https://doi.org/10.1016/S0378-1127(01)00511-4)
- Nepstad, D., Schwartzman, S., Bamberger, B., Santilli, M., Ray, D., Schlesinger, P., Lefebvre, P., Alencar, A., Prinz, E., Fiske, G., Rolla, A., 2006. Inhibition of Amazon deforestation and fire by parks and indigenous lands. *Conserv. Biol.* 20, 65–73. <https://doi.org/10.1111/j.1523-1739.2006.00351.x>
- Nepstad, D.C., de Carvalho, C.R., Davidson, E.A., Jipp, P.H., Lefebvre, P.A., Negreiros, G.H., da Silva, E.D., Stone, T.A., Trumbore, S.E., Vieira, S., 1994. The role of deep roots in the hydrological and carbon cycles of Amazonian forests and pastures. *Nature* 372, 666–669. <https://doi.org/10.1038/372666a0>
- Nepstad, D.C., Stickler, C.M., Filho, B.S.-, Merry, F., 2008. Interactions among Amazon land use, forests and

- climate: prospects for a near-term forest tipping point. *Philos. Trans. R. Soc. B Biol. Sci.* 363, 1737–1746. <https://doi.org/10.1098/rstb.2007.0036>
- Neto, T.O., 2019. As rodovias na Amazônia: uma discussão geopolítica. *Confins*. <https://doi.org/10.4000/confins.21176>
- Nobre, C.A., Borma, L.D.S., 2009. ‘Tipping points’ for the Amazon forest. *Curr. Opin. Environ. Sustain.* 1, 28–36. <https://doi.org/10.1016/j.cosust.2009.07.003>
- Novack, T., Wang, Z., Zipf, A., 2018. A System for Generating Customized Pleasant Pedestrian Routes Based on OpenStreetMap Data. *Sensors* 18, 3794. <https://doi.org/10.3390/s18113794>
- Oliveira, S., Pereira, J.M.C., San-Miguel-Ayanz, J., Lourenço, L., 2014. Exploring the spatial patterns of fire density in Southern Europe using Geographically Weighted Regression. *Appl. Geogr.* 51, 143–157. <https://doi.org/10.1016/j.apgeog.2014.04.002>
- Over, M., Schilling, A., Neubauer, S., Zipf, A., 2010. Generating web-based 3D City Models from OpenStreetMap: The current situation in Germany. *Comput. Environ. Urban Syst.* 34, 496–507. <https://doi.org/10.1016/j.compenvurbsys.2010.05.001>
- Pacheco, P., 2009. Agrarian Reform in the Brazilian Amazon: Its Implications for Land Distribution and Deforestation. *World Dev.* 37, 1337–1347. <https://doi.org/10.1016/j.worlddev.2008.08.019>
- Pavão, V.M., Querino, C.A.S., Beneditti, C.A., Pavão, L.L., Querino, J.K.A. da S., Machado, N.G., Biudes, M.S., 2015. Temperatura e albedo da superfície por imagens TM Landsat 5 em diferentes usos do solo no sudoeste da Amazônia brasileira. *Rev. Bras. Climatol.* 16, 169–183. <https://doi.org/10.5380/abclima.v16i0.40128>
- Peres, C.A., Zimmerman, B., 2001. Perils in parks or parks in peril? Reconciling conservation in Amazonian reserves with and without use. *Conserv. Biol.* 15, 793–797. <https://doi.org/10.1046/j.1523-1739.2001.015003793.x>
- Perz, S., Brilhante, S., Brown, F., Caldas, M., Ikeda, S., Mendoza, E., Overdevest, C., Reis, V., Reyes, J.F., Rojas, D., Schmink, M., Souza, C., Walker, R., 2008. Road building, land use and climate change: Prospects for environmental governance in the Amazon. *Philos. Trans. R. Soc. B Biol. Sci.* 363, 1889–1895. <https://doi.org/10.1098/rstb.2007.0017>
- Pourghasemi, H.R., Gayen, A., Lasaponara, R., Tiefenbacher, J.P., 2020. Application of learning vector quantization and different machine learning techniques to assessing forest fire influence factors and spatial modelling. *Environ. Res.* 184, 109321. <https://doi.org/10.1016/j.envres.2020.109321>
- Rappaport, D.I., Morton, D.C., Longo, M., Keller, M., Dubayah, R., Dos-Santos, M.N., 2018. Quantifying long-term changes in carbon stocks and forest structure from Amazon forest degradation. *Environ. Res. Lett.* 13, 2000–2010. <https://doi.org/10.1088/1748-9326/aac331>
- Ricketts, T.H., Soares-Filho, B., da Fonseca, G.A.B., Nepstad, D., Pfaff, A., Peterson, A., Anderson, A., Boucher, D., Cattaneo, A., Conte, M., Creighton, K., Linden, L., Maretti, C., Moutinho, P., Ullman, R., Victurine, R., 2010. Indigenous Lands, Protected Areas, and Slowing Climate Change. *PLoS Biol.* 8, e1000331. <https://doi.org/10.1371/journal.pbio.1000331>
- Rodrigues, M., de la Riva, J., 2014. An insight into machine-learning algorithms to model human-caused wildfire occurrence. *Environ. Model. Softw.* 57, 192–201. <https://doi.org/10.1016/j.envsoft.2014.03.003>
- Rodrigues, M., de la Riva, J., Fotheringham, S., 2014. Modeling the spatial variation of the explanatory factors of human-caused wildfires in Spain using geographically weighted logistic regression. *Appl. Geogr.* 48, 52–63. <https://doi.org/10.1016/j.apgeog.2014.01.011>
- Santana, N., de Carvalho Júnior, O., Gomes, R., Guimarães, R., 2018. Burned-Area Detection in Amazonian Environments Using Standardized Time Series Per Pixel in MODIS Data. *Remote Sens.* 10, 1904. <https://doi.org/10.3390/rs10121904>
- Sari, F., 2021. Forest fire susceptibility mapping via multi-criteria decision analysis techniques for Mugla,

- Turkey: A comparative analysis of VIKOR and TOPSIS. *For. Ecol. Manage.* 480, 118644. <https://doi.org/10.1016/j.foreco.2020.118644>
- Scholz, S., Knight, P., Eckle, M., Marx, S., Zipf, A., 2018. Volunteered Geographic Information for Disaster Risk Reduction—The Missing Maps Approach and Its Potential within the Red Cross and Red Crescent Movement. *Remote Sens.* 10, 1239. <https://doi.org/10.3390/rs10081239>
- Schroeder, W., Alencar, A., Arima, E., Setzer, A., 2009. The spatial distribution and interannual variability of fire in Amazonia. *Geophys. Monogr. Ser.* 186, 43–60. <https://doi.org/10.1029/2008GM000724>
- Shimabukuro, Y.E., Miettinen, J., Beuchle, R., Grecchi, R.C., Simonetti, D., Achard, F., 2015. Estimating Burned Area in Mato Grosso, Brazil, Using an Object-Based Classification Method on a Systematic Sample of Medium Resolution Satellite Images. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 8, 4502–4508. <https://doi.org/10.1109/JSTARS.2015.2464097>
- Silva Junior, C.H.L., Pessôa, A.C.M., Carvalho, N.S., Reis, J.B.C., Anderson, L.O., Aragão, L.E.O.C., 2021. The Brazilian Amazon deforestation rate in 2020 is the greatest of the decade. *Nat. Ecol. Evol.* 5, 144–145. <https://doi.org/10.1038/s41559-020-01368-x>
- Silvério, D. V., Brando, P.M., Bustamante, M.M.C., Putz, F.E., Marra, D.M., Levick, S.R., Trumbore, S.E., 2019. Fire, fragmentation, and windstorms: A recipe for tropical forest degradation. *J. Ecol.* 107, 656–667. <https://doi.org/10.1111/1365-2745.13076>
- Sitanggang, I.S., Yaakob, R., Mustapha, N., Ainuddin, A.N., 2013. Predictive Models for Hotspots Occurrence using Decision Tree Algorithms and Logistic Regression. *J. Appl. Sci.* 13, 252–261. <https://doi.org/10.3923/jas.2013.252.261>
- Soares-Filho, B., Alencar, A., Nepstad, D., Cerqueira, G., Del Carmen Vera Diaz, M., Rivero, S., Solórzano, L., Voll, E., 2004. Simulating the response of land-cover changes to road paving and governance along a major Amazon highway: The Santarém-Cuiabá corridor. *Glob. Chang. Biol.* 10, 745–764. <https://doi.org/10.1111/j.1529-8817.2003.00769.x>
- Soares-Filho, B., Moutinho, P., Nepstad, D., Anderson, A., Rodrigues, H., Garcia, R., Dietzsch, L., Merry, F., Bowman, M., Hissa, L., Silvestrini, R., Maretti, C., 2010. Role of Brazilian Amazon protected areas in climate change mitigation. *Proc. Natl. Acad. Sci.* 107, 10821–10826. <https://doi.org/10.1073/pnas.0913048107>
- Tremblay, S., Lucotte, M., Revéret, J.-P., Davidson, R., Mertens, F., Passos, C.J.S., Romaña, C.A., 2015. Agroforestry systems as a profitable alternative to slash and burn practices in small-scale agriculture of the Brazilian Amazon. *Agrofor. Syst.* 89, 193–204. <https://doi.org/10.1007/s10457-014-9753-y>
- Urzedo, D., Chatterjee, P., 2021. The Colonial Reproduction of Deforestation in the Brazilian Amazon: Violence Against Indigenous Peoples for Land Development. *J. Genocide Res.* 23, 302–324. <https://doi.org/10.1080/14623528.2021.1905758>
- Wuyts, B., Champneys, A.R., House, J.I., 2017. Amazonian forest-savanna bistability and human impact. *Nat. Commun.* 8, 15519. <https://doi.org/10.1038/ncomms15519>
- Yang, J., He, H.S., Shifley, S.R., Gustafson, E.J., 2007. Spatial Patterns of Modern Period Human-Caused Fire Occurrence the Missouri Ozark Highlands. *For. Sci.* 53, 1–15. <https://doi.org/10.1093/forestscience/53.1.1>
- Zhang, Y., Lim, S., Sharples, J.J., 2016. Modelling spatial patterns of wildfire occurrence in South-Eastern Australia. *Geomatics, Nat. Hazards Risk* 7, 1800–1815. <https://doi.org/10.1080/19475705.2016.1155501>