

UNIVERSIDADE FEDERAL DO ACRE
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
CENTRO DE FILOSOFIA E CIÊNCIAS HUMANAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA: MESTRADO EM
GEOGRAFIA

Jardel Anderson Freitas de Melo

**ANÁLISE DO FOGO NA RESERVA EXTRATIVISTA CHICO MENDES: Utilização
de Redes Neurais para classificação de focos de calor**

RIO BRANCO – ACRE, BRASIL
2023

Jardel Anderson Freitas de Melo

**ANÁLISE DO FOGO NA RESERVA EXTRATIVISTA CHICO MENDES: Utilização
de Redes Neurais para classificação de focos de calor**

Dissertação apresentada ao Programa de Pós-Graduação em Geografia da Universidade Federal do Acre, para obtenção do título de Mestre em Geografia, área de concentração Produção do espaço e ambiente nas fronteiras da Amazônia Sul Ocidental. Linha de pesquisa: Análise da Dinâmica Socioambiental. Requisito para obtenção do título de Mestre em Geografia.

Orientador: Prof^a. Ph.D. Karla da Silva Rocha.

RIO BRANCO – ACRE, BRASIL
2023

Ficha catalográfica elaborada pela Biblioteca Central da UFAC

- M528a Melo, Jardel Anderson Freitas, 1995 -
 Análise do fogo na reserva extrativista Chico Mendes: utilização de redes neurais para classificação de focos de calor/ Jardel Anderson Freitas de Melo; Orientadora: Prof^a. Ph.D. Karla da Silva Rocha. -- 2023.
 87 f.: il.; 30 cm.
- Dissertação (Mestrado) – Universidade Federal do Acre, Programa de Pós-Graduação em Geografia, 2023.
 Inclui referências bibliográficas, anexos e apêndices.
1. Reserva Extrativista Chico Mendes. 2. Queimada. 3. Incêndio. I. Rocha, Karla da Silva. (orientadora) II. Título.

CDD: 910

Dedicatória

Dedico esta dissertação a Deus, fonte de todo conhecimento e sabedoria.

Aos meus amados pais, Eder Viana e Andreia Linhares, minha gratidão eterna por serem os pilares do meu crescimento. Vocês sempre acreditaram em mim, encorajaram meus sonhos e estiveram ao meu lado em cada passo do caminho.

Aos meus queridos irmãos, Jardeson, Jasmim e Sarah, nossa união e cumplicidade são um presente inestimável que carrego no coração.

A vocês cinco, meu agradecimento sincero por serem minha família, meu porto seguro e minha motivação.

Agradecimento

A concretização desta dissertação de mestrado não teria sido possível sem o apoio, incentivo e orientação de muitas pessoas e instituições excepcionais, às quais dedico meus mais profundos agradecimentos.

À minha estimada orientadora, Professora Dra. Karla da Silva Rocha, expresso minha gratidão pela sua orientação diligente, sua expertise e sua dedicação ao meu crescimento acadêmico. Suas instruções perspicazes, sugestões valiosas e paciência incansável foram fundamentais para moldar esta pesquisa e me ajudar a superar os desafios.

À Universidade Federal do Acre, agradeço por fornecer um ambiente propício à aprendizagem e à pesquisa. O compromisso com a excelência educacional gratuita e o acesso ao conhecimento contribuíram significativamente para o desenvolvimento deste trabalho.

Aos estimados professores do Programa de Pós-Graduação em Geografia, meu sincero reconhecimento pela partilha de conhecimentos e pelo estímulo intelectual que moldaram minha visão. Suas aulas, debates e insights foram inspiradores e fundamentais para a construção deste estudo.

Especialmente à Professora Doutora Maria de Jesus, coordenadora do programa, agradeço por liderar com paixão e dedicação, proporcionando um ambiente de aprendizado estimulante e colaborativo. Sua liderança e apoio foram essenciais para o meu crescimento.

Por fim, expresso minha gratidão a todos aqueles que, direta ou indiretamente, contribuíram para este empreendimento acadêmico. Agradeço também à minha família e amigos pelo apoio emocional e encorajamento constantes.

Este trabalho é o resultado de um esforço conjunto e do comprometimento. Estou profundamente grato por todos os que compartilharam essa jornada comigo.

Com sincera gratidão,

Jardel Anderson.

RESUMO

A Amazônia abriga a maior floresta tropical contínua do mundo e desempenha um papel fundamental na regulação do clima global. No entanto, a ação do fogo na região representa um desafio urgente, com potenciais danos à biodiversidade, ao meio ambiente e às comunidades locais. Em 2022, o Brasil testemunhou uma perda alarmante de 16,3 milhões de hectares de floresta devido a atividades relacionadas ao fogo, e a Reserva Extrativista Chico Mendes (RECM), no estado do Acre, destaca-se como a segunda unidade de conservação federal mais ameaçada por incêndios. Por se caracterizar como uma importante área de proteção, torna-se crucial encontrar métodos eficazes para a prevenção e gerenciamento de áreas com risco de fogo. Nesse contexto, a inteligência artificial, especialmente as Redes Neurais Artificiais (RNA), têm se destacado como um modelo eficaz de predição em diversas áreas. O presente estudo o padrão de ocorrência do fogo, sua relação com o desmatamento e outras variáveis na RECM, assim desenvolver uma RNA capaz de prever a ocorrência de focos de calor na reserva de modo a auxiliar na tomada de decisão no que se refere à mitigação dos efeitos das mudanças climáticas globais. Para isso, foram utilizadas técnicas de sensoriamento remoto, densidade de Kernel e análise de correlação espacial de Pearson e Moran de variáveis propulsoras com os focos de calor. Na construção da RNA foi utilizado o software R Studio 4.2.3, em conjunto com o pacote "keras" e o framework "TensorFlow", para a construção de uma RNA do tipo Multilayer Perceptron, utilizando o algoritmo de retropropagação de aprendizagem. Resultados indicaram que as variáveis desmatamento, altitude, distância de ramais e rodovias juntamente com fatores climáticos, como vento, umidade relativa, umidade do solo, precipitação e irradiação solar, apresentaram correlação significativa com a ocorrência de incêndios na reserva. Os resultados da RNA construídas revelaram uma acurácia do modelo de 74%, uma sensibilidade de 76% e especificidade de 71%. Além disso, a taxa de verdadeiros positivos alcançou 81%, enquanto a de verdadeiros negativos foi de 64%. Até este ponto, os resultados obtidos sinalizam uma base sólida do modelo de RNA, indicando seu potencial para contribuir no monitoramento de focos de calor em áreas de relevância ambiental. Os resultados obtidos demonstraram o potencial promissor da RNA na identificação de áreas propícias a focos de calor, fornecendo uma ferramenta valiosa para a prevenção e gestão desses incêndios.

Palavras-chave: Reserva Extrativista Chico Mendes, fogo, Redes Neurais Artificiais

ABSTRACT

The Amazon is home to the largest continuous rainforest in the world and plays a key role in regulating the global climate. However, the action of fire in the region represents an urgent challenge, with potential damage to biodiversity, the environment and local communities. In 2022, Brazil witnessed an alarming loss of 16.3 million hectares of forest due to fire-related activities, and the Chico Mendes Extractive Reserve (RECM), in the state of Acre, stands out as the second federal conservation unit most threatened by fires. As it is characterized as an important protection area, it is crucial to find effective methods for the prevention and management of areas at risk of fire. In this context, artificial intelligence, especially Artificial Neural Networks (ANN), have stood out as an effective model of prediction in several areas. The present study the pattern of occurrence of fire, its relationship with deforestation and other variables in the RECM, thus developing an ANN capable of predicting the occurrence of hot spots in the reserve in order to assist in decision making regarding mitigation of the effects of global climate change. For this, remote sensing techniques, Kernel density and Pearson and Moran spatial correlation analysis of driving variables with hot spots were used. In the construction of the ANN, the R Studio 4.2.3 software was used, together with the "keras" package and the "TensorFlow" framework, for the construction of a Multilayer Perceptron type ANN, using the learning backpropagation algorithm. Results indicated that the variables deforestation, altitude, distance from branches and roads, together with climatic factors, such as wind, relative humidity, soil humidity, precipitation and solar radiation, showed a significant correlation with the occurrence of fires in the reserve. The results of the constructed ANN revealed a model accuracy of 74%, a sensitivity of 76% and specificity of 71%. Furthermore, the true positive rate reached 81%, while the true negative rate was 64%. Up to this point, the obtained results signal a solid basis for the ANN model, indicating its potential to contribute to the monitoring of hot spots in areas of environmental relevance. The results obtained demonstrate the promising potential of RNA in identifying areas conducive to hot spots, providing a valuable tool for the prevention and management of these fires.

Keywords: Chico Mendes Extractive Reserve, fire, Artificial Neural Networks

Lista de figuras

Figura 1 - Resex localizadas no estado do Acre.	23
Figura 2 - Histórico de focos de calor nas Resex federais do Acre. 2002-2021.....	25
Figura 3- Representação em blocos do sistema nervoso	26
Figura 4- Descrição de um neurônio biológico.	27
Figura 5- Modelo não linear de um neurônio.....	28
Figura 6- Função limiar.	29
Figura 7- Função linear por partes.	30
Figura 8 - - Função Sigmóide.....	30
Figura 9 - Arquitetura de redes.....	31
Figura 10 - Evolução da taxa de focos de queimadas na Reserva Extrativista Chico Mendes entre os anos de 2002 -2021	47
Figura 11 - Frequência dos focos de queimada no RECM. (A) 2002; (B) 2006; (C) 2010; (D) 2014; (E) 2018; e (F) 2021.	49
Figura 12 - Evolução da concentração de focos de calor na RECM entre 2002 a 2021.	50
Figura 13 - Variação das classes de densidade dos focos de calor na RECM entre 2002 a 2021.	52
Figura 14 - Evolução do desmatamento na Reserva Extrativista Chico Mendes entre os anos de 2002 -2021.....	52
Figura 15 - Sequência de fatos ocorridos antes e depois do foco localizado nas coordenadas UTM Zona 19, latitude 10°22'39.04"S e Longitude 68° 9'13.25"O: A:12/1985; B. 6/2013; C. 7/2013; D. 04/2021.....	53
Figura 16 - Desmatamento da Reserva Extrativista Chico Mendes.	54
Figura 18 - Relação entre área desmatada (km ²) e classes de densidade de focos de calor na Reserva Extrativista Chico Mendes.	55
Figura 17 - Sobreposição da densidade de focos de calor com o desmatamento da Reserva Extrativista Chico Mendes entre os anos de 2002 a 2021.	55
Figura 19 - Variação média das variáveis da RECM.....	56
Figura 20 – Matriz de correlação de correlação linear de Pearson	57
Figura 21 - Médias anuais das variáveis metrológicas.....	63
Figura 22 - Ramais internos da RECM é rodovias próximas.....	64

Figura 23 - Topografia da RECM	64
Figura 24 – Grade interna 1 x 1 km da Resex.....	66
Figura 25 - Resultados do Índice de Kappa para avaliação dos modelos	71
Figura 26 - Modelo da RNA construído.	72
Figura 27 - Comparação entre os focos de calor observados na Resex em 2020 e os valores previstos pelo modelo de RNA.	74

Sumário

1. INTRODUÇÃO GERAL.....	11
2. ESTRUTURA DA DISSERTAÇÃO	13
CAPÍTULO 1 REVISÃO BIBLIOGRÁFICA	14
1.1 O FOGO NA AMAZÔNIA.....	14
1.1.1 Aspectos climáticos.....	16
1.1.2 Aspectos antrópicos	17
1.1.3 Fatores topográficos.....	18
1.1.4 Características da vegetação	18
1.2 SENSORIAMENTO REMOTO	19
1.2.1 Focos de calor.....	20
1.3. RESERVA EXTRATIVISTA	21
1.3.1 Reservas extrativistas no Acre	23
1.4. REDES NEURAIS ARTIFICIAIS	26
1.4.1 Neurônio artificial.....	28
1.4.2 Tipos de arquiteturas de redes neurais	30
1.4.3 Processo de aprendizagem.....	32
1.4.4 Algoritmo de retroprogramação.....	35
CAPÍTULO 2: ANÁLISE DO REGIME FOGO NA RESERVA EXTRATIVISTA CHICO MENDES E SUAS CORRELAÇÕES COM FATORES PROPULSORES	37
2.1 INTRODUÇÃO	37
2.2.1 Fogo, queimadas, incêndios florestais e focos de calor	39
2.2.2 Fatores que influenciam o fogo	40
2.2.3 Correlação de Pearson	41
2.2.4 Índice de Moran.....	42
2.2 METODOLOGIA	43

2.2.1 Coleta dos dados	43
2.2.2 Procedimentos preparatórios	45
2.2.3 Avaliação das variáveis.....	46
2.3 RESULTADOS E DISCUSSÃO	47
2.3.1 Evolução de focos de calor	47
2.3.2 Relação focos de calor e desmatamento	52
2.3.3 Correlação de variáveis.....	56
2.4 CONCLUSÃO	58
CAPÍTULO 3 - PREDIÇÃO DE ZONAS PROPENSAS A FOCOS DE CALOR NA RESERVA EXTRATIVISTA CHICO MENDES POR MEIO DE REDE NEURAL ARTIFICIAL	60
3.1 INTRODUÇÃO	60
3.2 MATERIAIS E MÉTODOS	61
3.2.1 Coleta de dados	61
3.2.2 Preparação dos dados	65
3.2.3 Construção da RNA	66
3.3 RESULTADOS E DISCUSSÕES	71
3.4 CONCLUSÃO	75
CONSIDERAÇÕES FINAIS.....	76
REFERÊNCIAS.....	77

1. INTRODUÇÃO GERAL

A intensificação dos incêndios florestais é uma questão de grande importância científica e ambiental. Segundo Tyukavina et al. (2022), cerca de 9,3 milhões de hectares foram incendiados em todo o mundo apenas no ano de 2021, resultando em uma perda de aproximadamente um terço da cobertura vegetal. Os incêndios florestais são reconhecidos como um dos principais agentes de degradação das florestas, tanto de forma direta quanto indireta, através do desequilíbrio dos ecossistemas (Santos et al., 2010). Além disso, os incêndios globais são responsáveis por cerca de 1,8 gigatoneladas de emissão de dióxido de carbono (CO₂) por ano na atmosfera (BO ZHENG et al., 2021).

O Brasil é considerado um dos principais emissores de CO₂ provenientes dos incêndios florestais, especialmente na região amazônica (SOUZA et al., 2012). As atividades econômicas de madeireira e agropecuária são apontadas como as principais responsáveis pelo aumento dos incêndios florestais na Amazônia (Batista, 2004).

As consequências dos incêndios florestais são de grande impacto ao ecossistema e incluem a degradação do solo, a perda da biodiversidade e a quebra do ciclo hidrológico (SAMPAIO, 2006). Além disso, os incêndios florestais também apresentam riscos significativos para a saúde humana, devido às emissões de gases tóxicos que podem comprometer o sistema respiratório e causar problemas cardiorrespiratórios (RIBEIRO E ASSUNÇÃO, 2002).

As Unidades de Conservação (UCs) são consideradas como uma das medidas mais eficazes para combater o desmatamento e os incêndios florestais na Amazônia (BARBER et al., 2014). No entanto, Sampaio (2006) alerta para o aumento dos incêndios florestais dentro das UCs, devido à falta de serviços estruturados de prevenção e combate aos incêndios.

No estado do Acre, a Reserva Extrativista Chico Mendes (RECM) entrou para o grupo das 50 unidades de conservação críticas da Amazônia em 2015 (Araújo et al., 2015), e em 2020 registrou a maior área queimada (27.500 ha) entre as unidades de conservação do estado (SILVA et al., 2020).

A determinação de áreas com maior risco de incêndio é fundamental para o planejamento eficaz de prevenção e controle de incêndios florestais. A análise das

condições climáticas e ambientais propícias às queimadas permite estabelecer estratégias para prevenir e combater incêndios, bem como conscientizar a população local sobre os riscos envolvidos e, em casos extremos, restringir o acesso a áreas de alto risco (NUNES, 2006).

A utilização de redes neurais artificiais (RNAs) na modelagem de incêndios apresenta vantagens significativas, tais como a capacidade de serem aplicadas em sistemas sem soluções específicas, não necessitando de conhecimento dos processos físicos causadores do fenômeno, minimizando os erros de medição, possibilitando o treinamento contínuo da rede, permitindo a otimização entre os dados de entrada e saída e permitindo modelar processos com séries temporais de entrada e saída (HAYKIN, 2001).

Diante disso, este estudo tem como objetivo caracterizar e mapear as regiões de risco de incêndio na Reserva Extrativista Chico Mendes (RECM) utilizando um modelo de previsão baseado em RNAs de treinamento supervisionado, considerando variações de níveis de variáveis ambientais (número de focos e área queimada) e meteorológicas (temperatura do ar e do solo, umidade relativa do ar, quantidade de água no solo, velocidade do vento e radiação solar). Este estudo busca responder às seguintes perguntas: 1) Como se dá a distribuição de focos de calor e sua relação com o desmatamento na RECM? 2) Qual o desempenho do método de RNAs aplicado à previsão de risco de incêndio? 3) Qual a localização e dimensão das áreas que têm maior risco de incêndios na RECM? 4) Os riscos estão mais associados a fatores humanos ou ambientais? 5) Como o uso de dados de satélites auxilia na prevenção de incêndios na RECM?

Os resultados obtidos através deste estudo permitiram o estabelecimento de áreas prioritárias para o planejamento de atividades logísticas das equipes de combate a incêndios, visando minimizar os danos causados pelos incêndios e direcionar políticas públicas de incentivo e monitoramento de fogo e desmatamento zero.

2. ESTRUTURA DA DISSERTAÇÃO

A presente dissertação está estruturada em três capítulos.

O primeiro capítulo consiste em uma revisão bibliográfica, onde se aborda a problemática dos incêndios em florestas, bem como os principais fatores que propiciam sua ocorrência nesses ambientes. Além disso, é discutido o contexto das Reservas Extrativistas (Resex), suas etapas de criação e seus objetivos, com foco especial nas Resex localizadas no estado do Acre. Nessa perspectiva, explora-se a razão pela qual a Reserva Extrativista Chico Mendes, no Acre, é considerada a mais ameaçada em termos de proteção ambiental, principalmente em relação às áreas sujeitas a queimadas. Por fim, são apresentadas as Redes Neurais Artificiais e as principais abordagens para sua construção.

No segundo capítulo, dedicou-se a uma análise minuciosa do regime de fogo da Reserva Extrativista Chico Mendes (REMC), com foco na sua evolução histórica ao longo do tempo. Além disso, investigaram-se as regiões da reserva mais afetadas pelos incêndios. Nesse contexto, buscou-se identificar e examinar as principais variáveis que atuam como propulsoras do fogo dentro da RECM. Para tanto, realizou-se uma análise de correlação dessas variáveis, empregando o coeficiente de Pearson, a fim de compreender melhor as relações existentes entre elas. Adicionalmente, foram conduzidas análises de correlação geoespacial de Moran, com o objetivo de identificar possíveis padrões espaciais nas ocorrências de fogo.

No capítulo três, foi desenvolvida uma Rede Neural Artificial (RNA) com o objetivo de prever os focos de calor dentro da Reserva Extrativista Chico Mendes (RECM). A RNA foi implementada na linguagem R, utilizando o software R Studio 4.2.3 em conjunto com os pacotes "keras" e "TensorFlow", com a finalidade de construir um modelo do tipo Multilayer Perceptron (MLP) utilizando o algoritmo de backpropagation. Os dados utilizados para a construção da rede foram coletados no período de 2016 a 2019, enquanto os dados de 2020 foram reservados para a validação do modelo.

CAPÍTULO 1 REVISÃO BIBLIOGRÁFICA

1.1 O FOGO NA AMAZÔNIA

A Floresta Amazônica é a maior floresta tropical do mundo, abrangendo nove países da América do Sul, sendo a maior parte localizada no Brasil (INPE, 2017). Nas últimas décadas ocorreu um aumento alarmante de focos de incêndio na região, o que tem causado efeitos devastadores para o meio ambiente e para as comunidades que dependem da floresta (LIMA et al., 2021).

O fogo na floresta amazônica ocorre principalmente devido à ação humana, seja intencional ou acidental (BARLOW et al., 2012). A prática mais comum é a queimada, que consiste na técnica de limpeza de áreas para a expansão agrícola, pecuária, mineração ilegal e invasões de terras (NEPSTAD et al., 2008). Porém, essa técnica arcaica e desordenada tem causado não apenas a destruição localizada das áreas queimadas, mas também contribui para o desmatamento, emissão de gases do efeito estufa e prejuízos irreversíveis à biodiversidade (ALENCAR et al., 2015).

A propagação da combustão do fogo pode ocorrer por meio de três mecanismos distintos: convecção, radiação e condução (GOLDAMMER, 1982). As condições meteorológicas são fatores cruciais para o comportamento do fogo, conforme afirmado por Torres et al. (2020), que especificam que temperatura, umidade relativa do ar, velocidade do vento e precipitação atuam diretamente na propagação do fogo. Elevações de temperatura combinadas com baixa umidade relativa do ar aumentam a evaporação dos vegetais, os tornando mais secos e mais suscetíveis à combustão. Por outro lado, ventos elevados intensificam a propagação e direcionam o fogo.

A ocorrência do fogo na floresta é frequente em períodos de baixa precipitação, que resultam na seca da vegetação e aumentam sua vulnerabilidade à combustão (ROCHA, 2016). Em específico, no estado do Acre, a seca amazônica, que ocorre entre os meses de julho e outubro, representa 95% das áreas queimadas (CHAVES, 2020).

Os impactos do fogo na Amazônia são preocupantes, afetando diversos aspectos ecológicos, socioeconômicos e climáticos (Aragão et al., 2018). Em primeiro lugar, a queima indiscriminada de árvores e vegetação libera grandes emissões de

dióxido de carbono (CO₂) na atmosfera, inspirando significativamente para o aquecimento global (Morton et al., 2005). Além disso, a biodiversidade é severamente preservada, uma vez que muitas espécies de animais e plantas não resistem às chamas ou perdem seus habitats naturais (Saxena et al., 2020).

A saúde humana também é prejudicada, já que a fumaça proveniente das queimadas pode causar problemas relatados como asma, bronquite e outras complicações pulmonares (Veras et al., 2021). A população local que depende da floresta para a subsistência, como ribeirinhos e indígenas, também enfrenta dificuldades adicionais, com a destruição de roças, pesca e caça (Assunção et al., 2017). Além disso, incêndios florestais podem ameaçar vidas humanas e infraestruturas em áreas urbanas vizinhas (Setzer, 2020).

Para entender a magnitude dessa problemática, é fundamental examinar os números relacionados às queimadas na Amazônia. Segundo o Instituto Nacional de Pesquisas Espaciais (INPE), o ano de 2019 registrou a maior quantidade de focos de incêndios na região desde 2010, representando um aumento de 30% em relação ao ano anterior (INPE, 2019). Em termos de área devastada, apenas no mês de agosto de 2019, cerca de 30 mil quilômetros quadrados foram suspensos por incêndios na Amazônia (INPE, 2019). Esses números alarmantes provocaram a urgência de ações mais efetivas para combater essa prática predatória.

Além do mais é necessário esclarecer as diferenças entre queimadas e incêndios florestais. As queimadas são a prática deliberada de incendiar áreas, geralmente para a abertura de novas áreas de cultivo e pastagens, com controle limitado sobre o controle do fogo (Alencar et al., 2015). Já os incêndios florestais referem-se a incêndios não controlados que ocorrem na vegetação local, muitas vezes se espalhando rapidamente e de forma descontrolada (Setzer, 2020). Ambos têm negativo, mas os incêndios florestais são ainda mais perigosos e difíceis de combater, colocando-se em risco não apenas a floresta, mas também a vida de animais e humanos (Setzer, 2020).

Barber et al. (2014) destacam que os incêndios florestais são um dos principais responsáveis pela degradação das florestas tropicais, e que em áreas como a Amazônia, o fogo não é um fenômeno natural, mas sim resultado da ocupação humana e das mudanças no uso e cobertura florestal. Além disso, os incêndios florestais representam uma ameaça ao ecossistema da Amazônia e, combinados com

o desmatamento, alteram gradativamente a dinâmica florestal, tornando-a ainda mais vulnerável a incêndios (MORELLO et al., 2020).

A utilização do fogo é comumente seguida de desmatamento e é frequentemente empregada na Amazônia, com o objetivo de remover a camada vegetal natural para tornar as áreas propícias à atividade agropecuária (MOTA et al., 2019). A queima é um método tradicional e de difícil substituição, pois é barato e acessível, mesmo em locais remotos (CABRAL et al., 2013).

A ignição do fogo na floresta é um processo complexo e não linear que resultam da interação entre processos bióticos e abióticos e são dependentes da escala geográfica (CHUVIECO et al., 2019). Aponte et al. (2016) identifica quatro fatores principais que contribuem para a ocorrência de incêndios florestais: aspectos climáticos e antrópicos, fatores topográficos e características da vegetação. A seguir, serão apresentados os principais influenciadores dos incêndios florestais.

1.1.1 Aspectos climáticos

Os aspectos climáticos são considerados como um dos principais determinantes dos padrões de incêndios florestais devido à sua influência direta na umidade dos combustíveis mortos, tais como serapilheira, gramíneas secas e material lenhoso não vivo. A umidade dos combustíveis é crucial para estabelecer o potencial de ignição e propagação do fogo (MARLON et al., 2013).

As variáveis climáticas que influenciam diretamente na umidade dos combustíveis incluem temperatura, precipitação, velocidade do vento, umidade do ar e pressão atmosférica (MARLON et al., 2013). A temperatura, como energia interna dos movimentos dos átomos e moléculas, desempenha um papel importante na fase evaporativa de combustão (HAMADEH et al., 2017). Um aumento na temperatura resulta em uma diminuição da umidade relativa dos materiais combustíveis, tornando-os mais suscetíveis a incêndios (LIU e ZHANG, 2015).

A relação entre a quantidade de água presente no ar e a quantidade máxima que poderia existir na mesma temperatura e pressão é conhecida como umidade relativa (HAMADEH et al., 2017). Quanto maior for a umidade relativa, menor será a evaporação e maior será a absorção de umidade dos materiais combustíveis. Por outro lado, quanto menor for a umidade relativa, maior será a evaporação e menor

será a umidade dos materiais. É importante notar que uma umidade acima de 75% é considerada como sem risco de incêndio, entre 55% e 75% o risco é baixo, entre 30% e 55% o risco é alto e abaixo de 30% é considerado como risco muito alto (LIU e ZHANG, 2015).

A precipitação é um fator crucial na determinação dos ciclos de incêndios florestais, sendo que períodos prolongados de seca estão fortemente associados à ocorrência de incêndios. No entanto, a ocorrência de precipitação uniforme durante a estação de seca pode diminuir a suscetibilidade de incêndios (FERREIRA, 2017; FLANNIGAN et al., 2013).

A propagação do fogo é diretamente influenciada pela direção e velocidade dos ventos, uma vez que o aumento de oxigênio causado pelos ventos eleva a condição de combustão e interfere na evaporação dos combustíveis, tornando-os mais secos e inflamáveis (DONG et al., 2021).

As condições climáticas estão relacionadas à pressão atmosférica, sendo que as áreas de alta pressão tendem a apresentar temperaturas elevadas e baixa umidade, o que favorece a ocorrência de incêndios. Por outro lado, as áreas de baixa pressão tendem a ser associadas a nuvens e precipitações (LIU e ZHANG, 2015)

1.1.2 Aspectos antrópicos

Os aspectos antrópicos na natureza referem-se às interferências humanas nos ecossistemas naturais. A degradação florestal resultante das atividades humanas, como a expansão de atividades agropecuárias e a urbanização, é uma das principais causas da perda da biodiversidade e um agente relevante na ocorrência de incêndios florestais, seja acidental ou criminoso (ADAB et al., 2013).

A expansão de atividades agropecuárias, bem como a urbanização, são os principais fatores que têm contribuído para a degradação e fragmentação dos ecossistemas florestais, sendo que o desmatamento e as queimadas na região da Amazônia são fortemente relacionados (ARAGÃO et al., 2018)

Além disso, as rodovias e estradas têm uma contribuição relevante nas ocorrências de incêndios florestais, especialmente na região Amazônica, onde o acesso facilitado a áreas remotas por meio dessas infraestruturas possibilita atividades como a agropecuária e a retirada de madeira, aumentando a probabilidade

de incêndios (CAÚLA et al., 2015). A densidade de rodovias também é apontada como um fator relevante para o aumento dos focos de incêndios (JÚNIOR et al., 2019).

1.1.3 Fatores topográficos

As características topográficas, altitude e declividade, são elementos moduladores de regiões, intervindo diretamente nas condições meteorológicas e climáticas, como a temperatura do ar, precipitação e radiação solar (CAÚLA et al., 2015). Além disso, eles também controlam a cobertura vegetal e o uso e ocupação do solo, o que, por sua vez, tem um impacto direto na ocorrência de incêndios e queimadas (PARENTE e PEREIRA, 2016).

Terrenos com alta declividade apresentam uma maior taxa de propagação de fogo devido ao sistema de pré-ignição por convecção eficiente e ignição por ponto de contato (CHUVIECO e CONGALTON, 1989).

A orientação do terreno também é um fator a ser observado, pois suas faces têm influência na exposição aos raios solares, afetando na taxa de secagem do material combustível (JUVANHOL, 2014). Quanto maior a incidência de radiação solar, maior será a temperatura do ar e menor será a umidade (EUGENIO et al., 2016).

1.1.4 Características da vegetação

A transformação dos elementos de paisagem, tais como a disponibilidade de massa vegetal, afeta diretamente a inflamabilidade dos materiais presentes na região, conforme descrito por Fonseca et al. (2019). Badia et al. (2019) demonstra que a ocorrência de incêndios florestais tem correlação direta com a alteração da cobertura vegetal realizada pela modificação do uso e ocupação do solo.

A estrutura de paisagem, que reflete a forma e o padrão do uso e ocupação do solo, tem um impacto significativo na frequência e severidade de incêndios, devido à sua influência na carga combustível da região, além de afetar o microclima local (AQUILUÉ et al., 2020).

Em áreas florestais, a densa vegetação intercepta a radiação solar, reduzindo a temperatura do ar e servindo como barreira à velocidade do vento, diminuindo assim a taxa de evaporação, e conseqüentemente, dificultando a perda de umidade dos

materiais combustíveis (NUNES et al., 2008; GOMES et al., 2020). Contudo, em áreas onde a paisagem florestal é modificada, especialmente pela ação humana, os níveis de evaporação e temperatura são alterados, aumentando a carga combustível dos materiais suscetíveis a incêndios (AQUILUÉ et al., 2020; GOMES et al., 2020).

1.2 SENSORIAMENTO REMOTO

O uso de sensoriamento remoto no monitoramento ambiental tem revolucionado o campo, fornecendo dados valiosos sobre a superfície terrestre (Abbasi et al., 2021). Essa tecnologia tem sido amplamente aplicada em diversas áreas, incluindo agricultura de precisão, estudos sobre mudanças climáticas e planejamento urbano (Balzter et al., 2018; Jensen et al., 2018; Li et al., 2020).

Uma aplicação específica do sensoriamento remoto é o monitoramento do desmatamento, que se tornou um grave problema ambiental em escala global. Técnicas de sensoriamento remoto, como o uso de modelos de altura de dossel derivados de dados LiDAR aéreo, têm possibilitado o mapeamento e monitoramento precisos do desmatamento e degradação florestal (Hansen et al., 2013; Hall et al., 2016).

Adicionalmente, o sensoriamento remoto tem se tornado amplamente adotado no monitoramento ambiental, permitindo a aquisição de informações sobre a superfície terrestre por meio da captura de sinais eletromagnéticos. Essa tecnologia desempenha um papel crucial no mapeamento e estudo de diversos processos e fenômenos, como o monitoramento do desmatamento, a detecção de poluição e a análise da qualidade do ar e da água (Gomes et al., 2018; Paulino et al., 2017; Lopes et al., 2016).

Uma das aplicações mais relevantes do sensoriamento remoto no monitoramento ambiental é a detecção e monitoramento de focos de calor ou áreas de intenso calor. Os focos de calor surgem principalmente de atividades humanas, como incêndios florestais e queimadas, e podem ter graves consequências ambientais, incluindo perda de habitat, degradação do solo e emissões de gases de efeito estufa (Silva et al., 2020; Araújo et al., 2019).

1.2.1 Focos de calor

Os focos de calor, também conhecidos como hotspots, são importantes ferramentas utilizadas para o monitoramento ambiental. Ao longo da história, o uso de hotspots tem desempenhado um papel fundamental na detecção e prevenção de incêndios florestais, além de auxiliar na gestão dos recursos naturais e na conservação da biodiversidade (IPAM, 2018).

A definição básica de um hotspot é uma área na superfície da Terra onde há um aumento significativo de temperatura em comparação com áreas adjacentes (Silva et al., 2020). Esse aumento de temperatura geralmente está relacionado ao fogo, seja causado por causas naturais como raios ou ações humanas como incêndios e incêndios criminosos (Silva et al., 2020). Os hotspots podem ser identificados por meio de técnicas de sensoriamento remoto, como imagens de satélite, que captam a radiação infravermelha na superfície da Terra (Barbosa et al., 2017).

A utilização de hotspots como metodologia de monitoramento ambiental é de extrema importância. Em primeiro lugar, esta técnica permite a detecção rápida de incêndios florestais, possibilitando ações imediatas para combatê-los e minimizar os danos causados (INPE, 2021). Além disso, o monitoramento contínuo dos hotspots possibilita o estabelecimento de estratégias de prevenção, como a identificação de áreas de alto risco e a implementação de medidas de educação ambiental (IPAM, 2018).

Outro benefício do uso de hotspots está relacionado ao manejo de recursos naturais. Por meio do monitoramento dessa variável, é possível identificar áreas que têm sido consistentemente impactadas por incêndios e, conseqüentemente, implementar ações voltadas para a recuperação e conservação dessas áreas (Pivello et al., 2019). A identificação de hotspots também pode auxiliar no combate a atividades ilegais como extração de madeira e desmatamento, já que essas práticas muitas vezes são precedidas de queimadas para facilitar o acesso e a extração de recursos (Setzer, 2009).

No entanto, o uso de hotspots também tem suas limitações e desvantagens. A detecção de focos de calor não significa necessariamente a existência de incêndios ativos, pois os focos de calor residual podem ser detectados após a ocorrência do incêndio (Tollefson, 2019). Além disso, a resolução espacial dos satélites utilizados

pode ser um problema, pois hotspots muito pequenos podem não ser detectados, dificultando a identificação de incêndios preliminares (WWF, 2019).

Outro desafio é a correta interpretação da origem dos hotspots. Por exemplo, raios podem causar incêndios naturais em áreas de difícil acesso, enquanto incêndios criminosos ocorrem frequentemente em regiões de fronteira agrícola (Setzer, 2009). Portanto, esforços conjuntos entre diferentes órgãos e instituições são necessários para interpretar e atribuir corretamente a origem dos hotspots, visando a devida ação e responsabilização (Dor, 2018).

No contexto do Brasil, um país com grande extensão de florestas e ecossistemas independentes, o uso de hotspots é de extrema importância. Segundo o Instituto Nacional de Pesquisas Espaciais (INPE), o monitoramento de hotspots é realizado por meio do programa de detecção ativa de incêndio denominado Programa de Monitoramento de Incêndios (INPE, 2021). Esse programa utiliza imagens de satélite operando na faixa do infravermelho e tem papel fundamental na prevenção e controle de incêndios florestais no país (INPE, 2021).

1.3. RESERVA EXTRATIVISTA

A história das reservas extrativistas no Brasil remonta ao início da década de 1980 (DE MORAES, ADAMS, 2021). Nesse período, o governo brasileiro iniciou a implementação de medidas de proteção ambiental visando conciliar a preservação da natureza com as atividades de subsistência das tradicionais (DE MORAES, ADAMS, 2021).

As reservas extrativistas foram criadas como uma forma de reconhecimento e proteção dos modos de vida adotados por comunidades indígenas, quilombolas e ribeirinhas que dependem dos recursos naturais para sua sobrevivência (DE MORAES, ADAMS, 2021).

A criação das reservas extrativistas está embasada na legislação brasileira, como o Sistema Nacional de Unidades de Conservação da Natureza (SNUC) e a Constituição Federal de 1988, que estabelecem a obrigação do Estado em preservar o meio ambiente e garantir os direitos culturais, sociais e intelectuais das comunidades tradicionais (DE MORAES, ADAMS, 2021).

Atualmente, existem 88 reservas extrativistas no Brasil, distribuídas por todo o território nacional, cobrindo uma área de aproximadamente 15,8 milhões de hectares (BRASIL, 2008).

Essas reservas são criadas por meio de decreto presidencial, após um processo de estudo e consulta pública. Cada reserva possui uma comunidade tradicional como população residente e é gerida por um conselho deliberativo composto por representantes das comunidades locais, órgãos governamentais e organizações não governamentais (BRASIL, 2008).

No entanto, as reservas extrativistas enfrentaram desafios para sua efetiva implementação e gestão (SILVA et al., 2017).

Um desses desafios é a pressão exercida por atividades ilegais, como a exploração madeireira e o garimpo, que representam ameaças diretas aos modos de vida tradicionais e aos ecossistemas presentes nas reservas (SILVA et al., 2017).

A falta de recursos para a vigilância e monitoramento das áreas também dificulta o combate a essas atividades ilegais (SILVA et al., 2017).

Outro desafio é a garantia dos direitos territoriais das comunidades tradicionais, uma vez que muitas vezes enfrenta conflitos fundiários e invasões de seus territórios por parte de empresas e grandes proprietários rurais (SILVA et al., 2017).

A falta de regularização fundiária e sobreposição de áreas protegidas com outras unidades de conservação e terras indígenas também gerou choques e insegurança para as comunidades tradicionais (SILVA et al., 2017).

Além disso, a ausência de políticas públicas adequadas para o desenvolvimento econômico sustentável das reservas extrativistas é outro desafio a ser enfrentado (FREITAS, 2012).

A dependência das atividades extrativistas tradicionais muitas vezes limita a geração de renda e a melhoria das condições de vida dos residentes (FREITAS, 2012).

É fundamental promover alternativas econômicas viáveis e compatíveis com a conservação dos recursos naturais, como o ecoturismo e a agroecologia, de forma a garantir a sustentabilidade das comunidades e a preservação dos ecossistemas (JANSEN, NUNES, SILVA, 2011).

No entanto, é necessário superar os desafios existentes para que essas áreas comprem efetivamente seu papel na conservação da natureza e no desenvolvimento socioeconômico das comunidades (DE MORAES, ADAMS, 2021).

1.3.1 Reservas extrativistas no Acre

Atualmente, o estado do Acre abriga cinco reservas extrativistas distintas (Figura 1), a saber: Alto Juruá, Cazumbá-Iracema, Chico Mendes, Tarauacá e Riozinho da Liberdade (Brasil, 2021). Essas áreas protegidas estão estrategicamente distribuídas em diversas regiões do estado, abrangendo uma ampla variedade de ecossistemas, como florestas amazônicas, manguezais e cursos d'água. Em conjunto, essas reservas formam uma extensa malha de conservação, desempenhando um papel fundamental na salvaguarda da biodiversidade e na manutenção dos modos de vida tradicionais das comunidades locais.

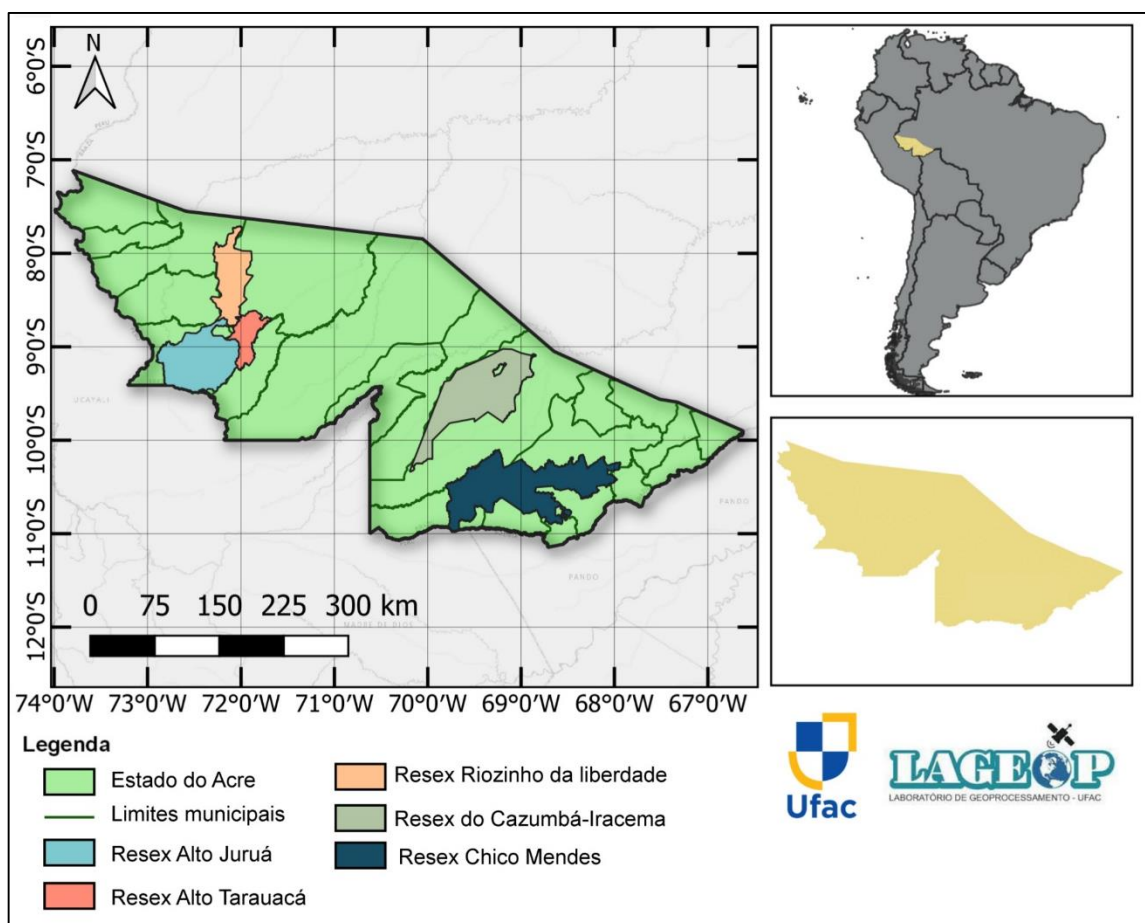


Figura 1 - Resex localizadas no estado do Acre.
Fonte: Os autores (2023).

A Reserva Extrativista Alto Juruá, destacando-se como uma das maiores do Acre, ocupa uma área de aproximadamente 497.849 hectares (ICMBio, 2021). Situada no extremo ocidental do estado, nas proximidades da fronteira com o Peru, a RESEX Alto Juruá engloba uma diversidade de paisagens, incluindo florestas inundáveis, corpos d'água e rios. Com uma população estimada em cerca de 1.632 famílias, composta por seringueiros, ribeirinhos e comunidades indígenas (Ferreira, 2018), essa reserva representa um importante centro de subsistência, com recursos naturais como borracha, castanha-do-brasil e atividades de pesca desempenhando um papel crucial em suas economias (Silveiro et al, 2019).

Datada de 17 de fevereiro de 2005, a Reserva Extrativista Riozinho da Liberdade se estende por 323.564 hectares e ocupa a bacia do rio Liberdade, abrangendo partes dos municípios de Tarauacá, Porto Walter, Marechal Thaumaturgo e Cruzeiro do Sul (BRASIL, 2005). Os moradores desta área dedicam-se a uma série de atividades agrícolas, com destaque para o cultivo de mandioca, milho, feijão, arroz e banana, além de atividades pecuárias como avicultura e bovinocultura (Silveiro et al, 2019).

A Reserva Extrativista Alto Tarauacá, criada em oito de novembro de 2000 (BRASIL, 2000), encontra-se nos municípios de Tarauacá, Marechal Thaumaturgo e Feijó. Nesta região, a exploração de recursos naturais como borracha e castanha-do-brasil tem um impacto econômico significativo, coexistindo com outras atividades de menor escala, como a extração de cipó-timbó e açaí (Silveiro et al, 2019).

A RESEX Cazumbá-Iracema, com uma extensão de 754.276 hectares, posiciona-se nos municípios de Sena Madureira e Manoel Urbano. Esta reserva, criada por decreto S/N de 19 de setembro de 2002 (BRASIL, 2002), é habitada por cerca de 1.300 moradores agrupados em 270 famílias. Com suas atividades concentradas em unidades produtivas denominadas colocações, essas famílias têm na agricultura e na exploração sustentável de recursos florestais a base de sua subsistência (Silveiro et al, 2019).

A Reserva Extrativista Chico Mendes, com uma vastidão aproximada de 970.570 hectares (ICMBio, 2021), situa-se no sudoeste do estado e abrange porções dos municípios de Brasiléia, Xapuri e Rio Branco. O nome da reserva é uma homenagem a Chico Mendes, líder seringueiro que lutou incansavelmente pelos direitos dos extrativistas na Amazônia. Atualmente, cerca de 1.425 famílias vivem na

reserva, dependendo da coleta de borracha, da agricultura e da pesca para sua subsistência (Ferreira, 2018).

A Reserva Extrativista Chico Mendes destaca-se como a maior reserva extrativista do estado, seguida pela Cazumbá-Iracema e Alto Tarauacá. Todas essas reservas possuem um método de geração de renda para as famílias residentes, baseado predominantemente em atividades extrativistas. No entanto, ao examinar os níveis de ameaças enfrentadas por essas reservas no que concerne à incidência de incêndios, é evidente que a RECM historicamente enfrenta uma maior pressão do regime de fogo. Isso pode ser claramente observado no Figura 2, ao qual apresenta a comparação do número de focos de calor observados nas Resex. No ano de 2021, na RECM, foi registrada a presença de um total de 12.765 focos de calor. Esse número representa aproximadamente 83% de todos os focos registrados nas reservas extrativistas federais do estado do Acre (INPE, 2023).

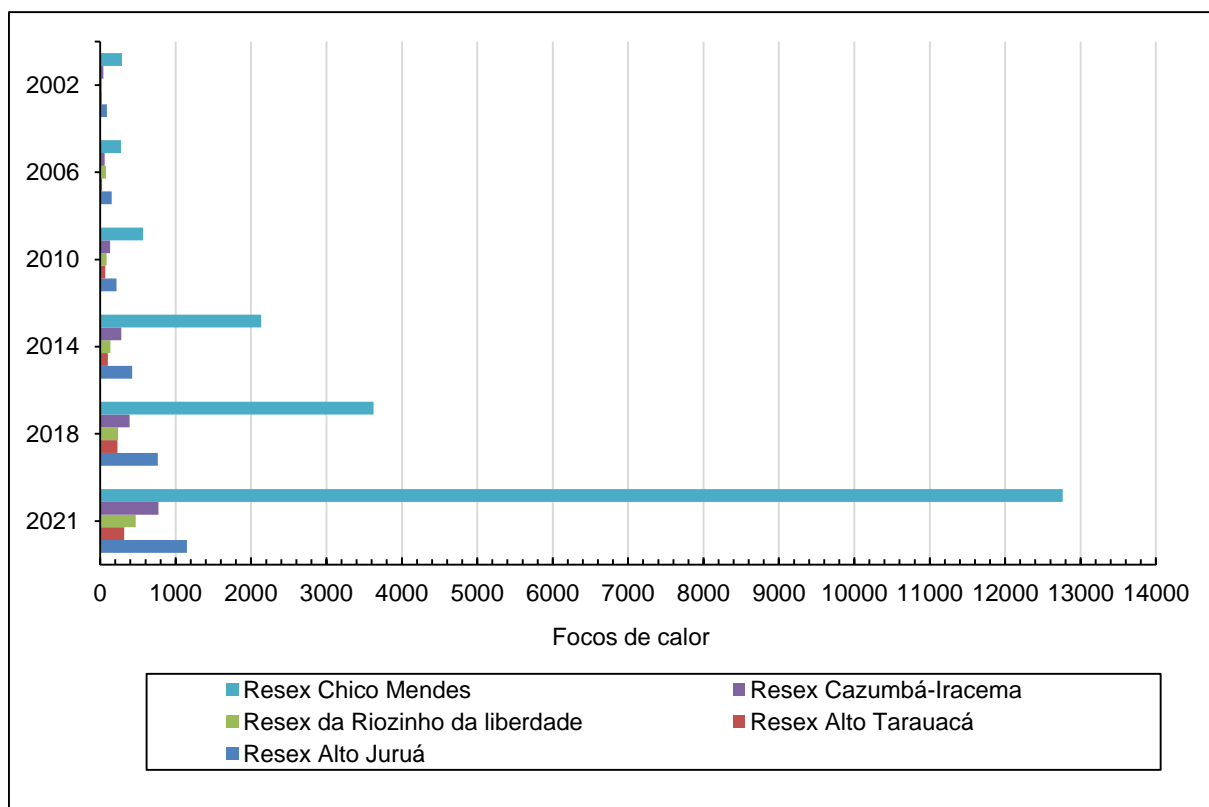


Figura 2 - Histórico de focos de calor nas Resex federais do Acre. 2002-2021.
Fonte: Os autores (2023).

1.4. REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA) são modelos computacionais baseados no processo de aprendizado de um cérebro biológico. Sua estrutura é composta por unidades de processamento simples, denominadas neurônios, que operam em paralelo, armazenando e tornando disponível informações para aplicações. A semelhança com o processo biológico de aprendizado é formulada através das conexões neurais, chamadas de pesos sinápticos, que armazenam o conhecimento adquirido (HAYKIN, 2001).

A analogia com o sistema nervoso humano pode ser feita através de três estágios: receptores, redes neurais e atuadores (Figura 3). Os receptores transformam estímulos sensoriais do corpo humano ou do ambiente externo em impulsos elétricos que são transmitidos à rede neural. A rede neural é o centro do sistema, portanto, é o cérebro, que recebe as informações e toma as decisões para os impulsos elétricos enviados. Importante observar que o processo da rede neural não é apenas de saída, pois também passa pelo processo de aprendizado, de acordo com a informação externa imposta, ou seja, uma realimentação do sistema. Por fim, os atuadores transformam os impulsos elétricos enviados pela rede neural em respostas como saída do sistema. (HAYKIN, 2001).




Figura 3- Representação em blocos do sistema nervoso
Fonte: Adaptado HAYKIN, 2001, p.32.

. O sistema nervoso central, especificamente o cérebro, é caracterizado por sua complexidade e dinamicidade, possuindo uma capacidade adaptativa e auto-organizacional de suas estruturas internas. O neurônio é uma das principais unidades funcionais deste sistema, sendo responsável pela transmissão de informação por meio de impulsos elétricos. As estruturas principais de um neurônio biológico incluem os dendritos, o corpo celular e o axônio (Figura 4). Os dendritos, estrutura de entrada, são responsáveis pela captação de impulsos elétricos, enquanto o corpo celular

processa e determina a ação que permitirá a propagação do sinal através do axônio. O axônio, por sua vez, é responsável pela propagação dos impulsos elétricos para os dendritos de outros neurônios em zonas ativas dos neurônios, conhecidas como sinapses (ROMERO, 2017).




Figura 4- Descrição de um neurônio biológico.
Fonte: Adaptado (VIÑUELA e LÉON, 2004, p.4.)

As RNAs foram inicialmente propostas em 1943 pelo neurofisiologista Warren McCulloch e pelo matemático Walter Pitts, com o objetivo de modelar o funcionamento dos neurônios através de uma rede neural simplificada utilizando circuitos elétricos. Desde então, com o avanço tecnológico computacional, as RNAs evoluíram e a compreensão do funcionamento das atividades cerebrais também se aprimorou (LÓPES e FERNÁNDES, 2008).

De acordo com Simon Haykin (2021), as RNAs podem ser entendidas como sendo "um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso". O autor aponta que as RNAs possuem duas semelhanças com as redes neurais biológicas: a capacidade de aprendizagem e o processo de armazenamento de conhecimento pelas conexões entre neurônios.

1.4.1 Neurônio artificial

O neurônio artificial (NA) é um elemento fundamental na estrutura de uma rede neural artificial, tendo a função de processar a informação. A Figura 5 apresenta um modelo não linear de uma unidade de processamento em uma NA. De acordo com Haykin (2001), três componentes compõem a estrutura de um NA: sinapses, junção aditiva e função de ativação. As sinapses são as conexões que permitem a transmissão de informação entre neurônios, a junção aditiva é responsável por combinar os sinais de entrada e a função de ativação é utilizada para determinar a saída do neurônio, a partir da combinação dos sinais de entrada.




Figura 5- Modelo não linear de um neurônio.
Fonte: (HAYKIN, 2001, p.36)

As sinapses são representadas matematicamente por meio da multiplicação das entradas (x_m) com os pesos sinápticos (w_m), os quais podem assumir valores positivos ou negativos. A junção aditiva é responsável pela soma dos sinais de entrada, resultando em uma combinação linear. A função de ativação, por sua vez, restringe a amplitude do sinal de saída em função dos argumentos, geralmente com amplitude de intervalo $[0,1]$ ou $[-1,1]$. Os bias (b_k) ou viés são aplicados externamente e têm o efeito de ajustar a entrada da função de ativação (HAYKIN, 2001).

Em termos de equações matemáticas um neurônio (k) pode ser apresentado com as seguintes equações:

$$y_k = \varphi(u_k + b_k) \quad (1)$$

e

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2)$$

Onde x_1, x_2, \dots, x_m são as entradas; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos; u_k é o resultado da junção aditiva; b_k é as bias; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal de saída do neurônio.

A função de ativação $\varphi(\cdot)$, defini a saída de um neurônio de acordo com os argumentos utilizados, definindo a linearidade ou não dos resultados da NA. Haykin (2021) apresenta os três tipos básicos das funções de ativação:

1. **Função Limiar:** neste modelo um neurônio assume o valor 0, caso o campo local induzido daquele neurônio for negativo, e 1 caso for positivo.

$$y_k = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases} \quad (3)$$




Figura 6- Função limiar.
Fonte: Adaptado (HAYKIN, 2001, p.39.)

2. **Função linear por partes:** o fator de amplificação dentro da região linear da operação se torna a unidade, podendo ser considerada uma aproximação do amplificador não-linear.

$$\varphi(v) = \begin{cases} 1, & v \geq \frac{1}{2} \\ v, & -\frac{1}{2} < v < \frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (4)$$




Figura 7- Função linear por partes.
Fonte: Adaptado (HAYKIN, 2001, p.39).

3. **Função Sigmóide:** é a mais utilizada na utilização da função de ativação das RNAs, tendo um balanceamento adequado entre comportamento linear e não linear. Um exemplo deste modelo é a função logística:

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (5)$$




Figura 8 - Função Sigmóide.
Fonte: Adaptado (HAYKIN, 2001, p.39.)

1.4.2 Tipos de arquiteturas de redes neurais

A arquitetura de uma RNA é um aspecto crucial para o sucesso do modelo no estudo de um determinado problema. De acordo com Braga (2000), é importante

estabelecer uma relação entre a arquitetura da RNA e o problema em questão. A composição da arquitetura da RNA é estruturada com base no número de entradas, camadas, neurônios e nós de saída.

Basicamente, as RNAs são compostas por camadas de entrada, intermediárias ou ocultas e saída. Segundo Haykin (2001), existem três tipos básicos de arquitetura de RNAs:

- **Redes alimentadas diretamente com Camada Única:** Este é o modelo mais simples de RNA, tendo apenas uma camada de entrada que se projeta diretamente na camada de saída. Este tipo de arquitetura é conhecido como alimentada adiante ou acíclica.
- **Redes alimentadas diretamente com Múltiplas Camadas:** Neste tipo de arquitetura, há a presença de camadas ocultas, cuja função é extrair estatísticas de ordem elevada entre as camadas de entrada e saída, tornando a rede capaz de processar informações complexas.
- **Redes recorrentes:** possuem laços de realimentação, permitindo um maior impacto de aprendizado e desempenho na RNA. Estas redes podem utilizar elementos de atraso unitário. Podendo também utilizar-se de elementos de atraso unitário (z^{-1}) resultando em uma dinâmica não-linear.

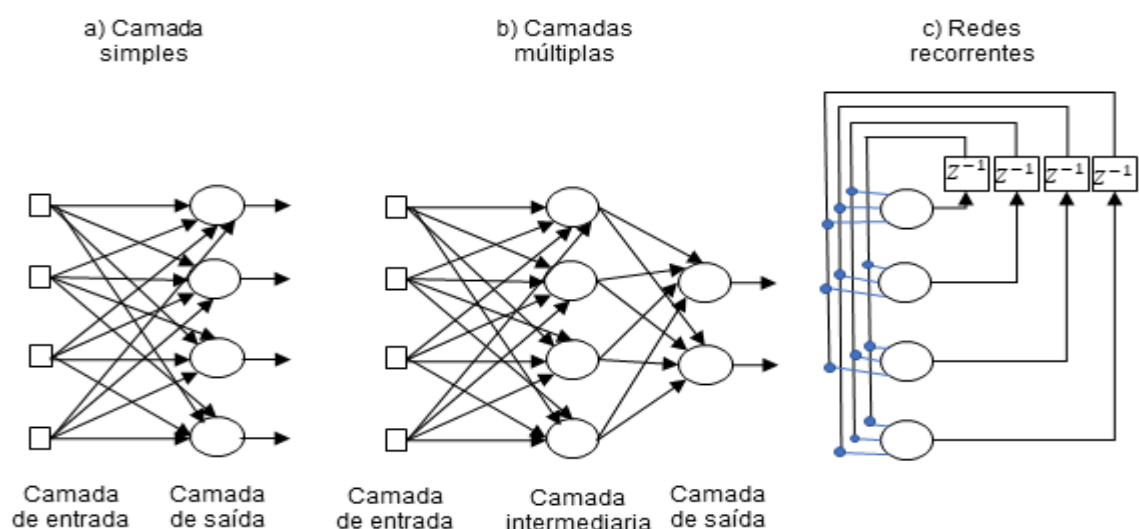


Figura 9 - Arquitetura de redes.
Fonte: Adaptado (HAYKIN, 2001, p.47 e 48)

As redes de múltiplas camadas, também conhecidas como MultiLayer Perceptron (MPL) ou Perceptron Multicamadas (PMC), são um tipo de arquitetura amplamente utilizado nas redes neurais (LÓPES e FERNÁNDES, 2008). Segundo Gonçalves (2009), essa arquitetura apresenta maior capacidade de análise em comparação com outras estruturas de redes neurais, devido à utilização de camadas ocultas, que são responsáveis pela captura de não-linearidades presentes nos dados.

1.4.3 Processo de aprendizagem

A capacidade de aprender e melhorar o desempenho através de aprendizado é uma característica fundamental das redes neurais. O processo de aprendizado ocorre através da interação entre os pesos sinápticos e os níveis de viés, aumentando a precisão da solução do problema a cada iteração (LÓPES e FERNÁNDES, 2008).

Segundo Haykin (2001), o algoritmo de aprendizagem é um conjunto de regras predefinidas para a resolução de problemas, onde existem várias maneiras de estabelecer as definições, cada uma oferecendo vantagens específicas. As cinco regras básicas de aprendizagem das RNAs são (HAYKIN, 2001):

- **Aprendizado por correção de erro:** baseada na comparação entre o sinal de saída $y_k(n)$ de um neurônio (k), com uma resposta desejada ou saída-alvo, representada por $d_k(n)$, originando um sinal de erro ($e_k(n)$), conforme a equação:

$$e_k(n) = d_k(n) - y_k(n) \quad (6)$$

O sinal de erro $e_k(n)$ processa o mecanismo de controle, que possui o objetivo de aplicar uma sequência de correções aos pesos sinápticos do neurônio k . Os ajustes buscam uma aproximação entre o sinal de saída $y_k(n)$ e a resposta desejada $d_k(n)$. A aproximação realizada nos ajustes é chamada de função de custo ou índice de desempenho, $E(n)$, sendo definida como:

$$E(n) = \frac{1}{2} e_k^2(n) \quad (7)$$

Os ajustes dos pesos sinápticos w_{kj} de um neurônio k excitado por um elemento $x_j(n)$ do vetor de sinal $x(n)$ no tempo n , é dado pelo ajuste $\Delta w_{kj}(n)$ e a taxa de aprendizagem (η) na seguinte equação:

$$\Delta w_{kj}(n) = \eta e_k(n) x_j(n) \quad (8)$$

Com o ajuste sináptico $\Delta w_{kj}(n)$, o valor do peso sináptico w_{kj} é determinado por:

$$w_{kj}(n + 1) = w_{kj}(n) + \Delta w_{kj}(n) \quad (9)$$

Os ajustes dos pesos sinápticos do neurônio k ocorrem até o sistema atingir um estado estável.

- **Aprendizagem baseada em memória:** todas as experiências passadas são armazenadas e uma memória de exemplos de entrada e saída: $\{(x_i, d_i)\}_{i=1}^N$, onde x_i é o vetor de entradas e d_i é a resposta desejada. Quando um vetor de teste (x_{teste}) deseja ser classificado, o algoritmo responde buscando em uma vizinhança local a resposta correspondente de x_{teste} .

A vizinhança local é definida como exemplo de treinamento, por se encontrar próximo do vetor x_{teste} . Portanto um vetor:

$$x'_N \in \{x_1, x_2, \dots, x_N\} \quad (10)$$

é o vizinho mais próximo de x_{teste} caso:

$$\min d(x_i, x_{teste}) = d(x'_N, x_{teste}) \quad (11)$$

onde $d(x_i, x_{teste})$ é a distância euclidiana entre os vetores x_i e x_{teste} .

- **Aprendizagem Hebbiana:** possui o princípio de aproximação entre neurônios. Se dois neurônios em ambos os lados de uma sinapse são ativados simultaneamente, a força de sua ligação é aumentada, caso o contrário a ligação da sinapse é enfraquecido ou eliminado. Uma

sinapse hebbiana depende do tempo, local e de interação para a correção pré-sinápticas e pós-sinápticas. A forma básica da equação de aprendizagem hebbiana é dado por:

$$\Delta w_{kj}(n) = \eta y_k(n)x_j(n) \quad (12)$$

Onde η é a taxa de aprendizagem, y_k é atividade pós-sináptica e x_j a atividade pré-sináptica.

- **Aprendizagem competitiva:** possui como característica a competição entre os neurônios de saída da RNA para serem ativados. Este método é muito utilizado para classificação de padrões de entradas. Possui três elementos básicos para sua aplicação:
 1. Um conjunto de neurônios iguais, exceto por seus pesos sinápticos que são distribuídos aleatoriamente;
 2. Um valor limite para ativação dos neurônios;
 3. Um mecanismo que permite a competição entre os neurônios, sendo somente um deste o vencedor.
- **Aprendizagem de Boltzmann:** os neurônios assumem uma estrutura binária, quando estão “ligados” assumem a representação de +1, quando “desligados” são representados por -1. A função de Energia, E , obtém seu valor pelos estados particulares dos neurônios individuais da máquina, conforme a equação a seguir:

$$E = \frac{1}{2} \sum_j \sum_k w_{kj} x_k x_j \quad (13)$$

onde x_j é o estado do neurônio j e w_{kj} é peso sináptico da conexão entre os neurônios j e k . A correlação entre dos neurônios j e k em uma condição presa (estado determinado pelo ambiente), p_{kj}^+ , e p_{kj}^- representa a condição de operação livre, a variação Δw_{kj} é expressa por:

$$\Delta w_{kj}(n) = \eta (p_{kj}^+ - p_{kj}^-), j \neq k \quad (14)$$

1.4.4 Algoritmo de retroprogramação

O algoritmo conhecido como retroprogramação de erro é baseado na regra de aprendizagem por correção de erro (HAYKIN, 2001). Sua aprendizagem consiste em duas etapas: uma etapa de propagação para frente (forward propagation), onde um vetor de entrada é inserido nos nós sensoriais da rede e percorre todas as camadas, com pesos sinápticos fixados, gerando, ao final, um conjunto de saída da rede; e uma etapa de propagação para trás (backpropagation), onde os pesos sinápticos são ajustados de acordo com a regra de correção. Esta correção é realizada através da subtração da resposta de rede com uma resposta desejada.

O objetivo do algoritmo de retroprogramação é minimizar a diferença entre a resposta da rede e a saída desejada (VIÑUELA e LÉON, 2008). Isso é alcançado através da otimização dos pesos sinápticos, com o intuito de aproximar a resposta da rede da saída desejada. Logo é um problema de minimização da seguinte maneira:

$$\text{Min}_w E \quad (15)$$

Onde W é o conjunto de parâmetros do neurônio (pesos sinápticos), e E é a função erro que avalia a diferença entre valores de saída da rede com as desejadas. A função erro é definida como:

$$E = \frac{1}{N} \sum_{n=1}^N e(n) \quad (16)$$

Sendo N é o tamanho do conjunto de interações e $e(n)$ é o erro cometido pelo neurônio, dado por:

$$e(n) = \frac{1}{2} \sum_{i=1} (s_i(n) - y_i(n))^2 \quad (17)$$

Onde $Y(n) = (y_1(n), \dots, y_n(n))$ e $S(n) = (s_1(n), \dots, s_n(n))$ são os vetores de saída do neurônio e a saída desejada para o padrão n , respectivamente.

As saídas dos neurônios ($Y(n)$) são retroalimentadas nas camadas de entrada, seu somatório ponderado produz a variável conhecida como campo local induzido ($v_j(n)$) definida como:

$$v_j(n) = \sum_{i=0}^m w_{kj}(n)y_k(n) \quad (18)$$

O algoritmo de retropropagação aplica a correção ($\Delta w_{jk}(n)$) aos pesos sinápticos de cada neurônio, utilizando-se da função de custo, conforme a seguir:

$$\Delta w_{jk}(n) = -\eta \frac{\partial e(n)}{\partial w_{jk}(n)} \quad (19)$$

Adicionando-se o parâmetro α , é possível modificar a correção do erro, também denominada de regra delta, evitando a convergência a um mínimo local da função. A função é dada por:

$$\Delta w_{jk}(n) = \alpha \Delta w_{jk}(n-1) + \eta \delta_j(n) y_k(n) \quad (20)$$

Sendo α definido entre os intervalos de 0 e 1, onde δ_j é o gradiente local do neurônio, definido por:

$$\delta_j(n) = -\frac{\partial e(n)}{\partial w_{jk}(n)} = e_j(n) \varphi'_j(v_j(n)) \quad (21)$$

CAPÍTULO 2: ANÁLISE DO REGIME FOGO NA RESERVA EXTRATIVISTA CHICO MENDES E SUAS CORRELAÇÕES COM FATORES PROPULSORES

2.1 INTRODUÇÃO

A exploração humana da natureza tem sido um assunto amplamente discutido devido ao crescente reconhecimento dos efeitos prejudiciais da utilização predatória. O Painel Intergovernamental sobre Mudanças Climáticas (IPCC) em seu relatório de avaliação de mudanças climáticas prevê um aumento de 1,1°C na temperatura global até 2022, e alerta para os impactos significativos e irreversíveis das emissões de gases de efeito estufa atualmente presentes até 2040 (IPCC, 2022).

O impacto do aquecimento global tem sido uma grande preocupação global nas últimas décadas, com efeitos significativos em várias regiões do mundo. Em 2019, a Austrália enfrentou uma das piores temporadas de incêndios florestais da história, conhecida como "verão negro". Este evento devastador resultou em 12 milhões de hectares de terra queimada e a morte de cerca de 1 milhão de animais (REGAN, 2020). Além disso, secas recordes também foram registradas em países líderes mundiais, incluindo Estados Unidos e China, em 2022 (PEIXOTO, 2022).

No Brasil, fenômenos climáticos raros, como ciclones (GRANCHI, 2022) e tempestades de areia (FRANCO, 2021), têm sido registrados e evidenciam os efeitos das mudanças climáticas. Esses eventos extremos têm um impacto significativo na sociedade, na economia e no meio ambiente.

As emissões de gases de efeito estufa, como o dióxido de carbono (CO₂), metano (CH₄) e óxido nitroso (N₂O), têm sido reconhecidas como responsáveis pelo aumento do efeito estufa global, resultando em mudanças climáticas significativas em todo o mundo (BERNOUX et al., 2001). No Brasil, um grande contribuinte para as emissões desses gases é a mudança no uso da terra, especificamente a prática de queima para preparação de áreas destinadas à agropecuária (BRASIL, 2009), respondendo por cerca de 70% das emissões no país.

De acordo com Fernside (2002), as queimadas, que geralmente acompanham os desmatamentos, liberam grandes quantidades de gases de efeito estufa, sendo uma problemática recorrente, especialmente no Bioma Amazônico. O Instituto de Pesquisa Ambiental da Amazônia (IPAM) registrou cerca de 15.000 km² de áreas

queimadas na Amazônia entre os meses de janeiro e julho de 2022, representando um aumento de 7% em relação ao mesmo período do ano anterior (IPAM, 2022).

Uma preocupação crescente é o avanço da presença do fogo em unidades de conservação (UCs). No Brasil, as UCs são delimitações territoriais destinadas à conservação e preservação ambiental (BRASIL, 2000), e são consideradas a mais eficaz ação governamental na conservação da natureza e amplamente utilizadas na luta contra as perdas de biodiversidade das últimas décadas (MMA, 2007).

A Reserva Extrativista (RESEX) é uma categoria de UCs, projetadas para conservar o estilo de vida extrativista das populações tradicionais e garantir a preservação ambiental. A criação das reservas foi idealizada por intermédio de reivindicações de movimentos seringalistas, com lideranças no estado do Acre, que protestavam contra a expansão da atividade agropecuária e o desflorestamento (ALLEGRETTI, 1989).

Neste contexto, as RESEXs têm grande importância na manutenção da floresta e redução do desmatamento, além da conservação da biodiversidade (ALMEIDA et al., 2018). No entanto, as atividades extrativistas não se consolidaram como garantia de renda para a população, e diante da insegurança econômica, as famílias adotaram atividades que divergem dos pressupostos iniciais (FREITAS et al., 2016), levando a mudanças no uso e cobertura da terra nessas áreas, e consequentemente, aumentando as áreas desmatadas e queimadas.

A Reserva Extrativista Chico Mendes (RECM), localizada no estado do Acre, tem sofrido com essas consequências. Em 2020, houve uma área de 27.500 ha queimadas (SILVA et al., 2020). De acordo com o Instituto Nacional de Estudos e Pesquisas (INEP), no ano de 2021, a RECM representou mais de 70% de todos os focos de queimadas de UCs no estado do Acre (INEP, 2022).

O aumento contínuo das áreas queimadas nos últimos anos impõe a necessidade urgente de uma política de monitoramento e fiscalização mais rigorosa, bem como o desenvolvimento e implementação de metodologias precisas para acompanhar essas mudanças.

A análise realizada por sensoriamento remoto é uma ferramenta valiosa no estudo do monitoramento de focos de calor, sendo utilizada por diversas instituições no esforço de conservação e preservação de espaços florestais (ROCHA et al., 2020).

Utilizando dados de satélites, é possível identificar pontos de queima em diversos territórios (JUNIOR et al., 2008).

Considerando que os focos de calor detectados por meio de sensoriamento remoto por satélites são indicadores de pontos de queimadas e incêndios florestais na Amazônia (BROWN et al., 2006), o objetivo deste capítulo é caracterizar a dinâmica temporal e espacial dos focos de calor e sua relação com o desmatamento na RECM. Além disso, pretende-se utilizar técnicas de análises estatísticas, incluindo o coeficiente de correlação de Pearson e o índice de Moran, para investigar a relação entre fatores que preponderantes no comportamento do fogo com os focos de calor da RECM nos últimos 19 anos (2002 a 2021).

2.2 FUNDAMENTAÇÃO TEORICA

2.2.1 Fogo, queimadas, incêndios florestais e focos de calor

A utilização do fogo em zonas destinadas à agricultura e pecuária é uma prática tradicionalmente empregada. Trata-se de um método de baixo custo e amplamente acessível, especialmente em áreas remotas, sendo, por essa razão, amplamente difundido nas regiões amazônicas (COPERTINO et al., 2019).

Ao ser empregado em determinado ecossistema, o fogo pode ser categorizado em dois padrões distintos: queimada ou incêndio florestal. A queimada é considerada uma técnica de uso controlado, seguindo um conjunto de critérios pré-estabelecidos, o que a torna segura e eficiente no manejo das atividades agropecuárias. Em contrapartida, os incêndios florestais são caracterizados pelo fogo descontrolado, que consome indiscriminadamente todos os tipos de vegetação presentes. (SOARES; BATISTA, 2007).

Embora apresentem diferenças entre si, tanto as queimadas quanto os incêndios florestais são considerados riscos significativos para a preservação ambiental, com impactos diretos sobre as áreas florestais. Esses impactos se manifestam de forma química, física e biológica, levando a perda irreversível da cobertura vegetal original, degradação do solo, perda de biodiversidade e interrupção do ciclo hidrológico (SAMPAIO, 2006).

Dessa maneira, a busca por meios efetivos de detecção de queimadas e incêndios florestais torna-se essencial na luta pela preservação e conservação

ambiental. Entre as técnicas mais empregadas na análise da propagação do fogo em determinadas áreas, destaca-se o monitoramento por focos de calor.

Os focos de calor consistem em registros identificados por meio de sensores embarcados em satélites, que captam a temperatura de brilho de um ponto específico na superfície terrestre, a qual pode chegar a 47 °C. Tal temperatura representa um valor significativamente elevado em relação à superfície terrestre, o que evidencia a ocorrência de atividades de fogo nesse ponto (INPE, 2007).

Ao se analisar os dados de focos de calor, é importante levar em consideração algumas limitações inerentes a essa abordagem, como a falta de informações em intervalos de passagens dos satélites, presença de nuvens na área afetada pelo fogo, bem como o fogo superficial em vegetação com dossel fechado, não detecção de fogos que não gerem focos de calor significativos. Desta forma, é preciso ter em mente que esses registros representam apenas uma fração do total de incêndios florestais e queimadas ocorridos em determinada área (PEREIRA et al., 2012)

Conforme afirmado por Setzer e Morelli (2011), a monitoração de regiões afetadas pelo uso do fogo, por meio da análise dos dados de focos de calor, é uma abordagem adequada para áreas remotas que não dispõem de outras formas de detecção em tempo real.

2.2.2 Fatores que influenciam o fogo

Os aspectos preponderantes que determinam o comportamento do fogo envolvem a qualidade do material combustível, as características climáticas, o tipo de vegetação e a presença humana. Essas variáveis podem ser agrupadas entre aquelas que impactam o risco de início de um incêndio e as que afetam a forma como este se propaga (VASCONCELOS e VENTURA, 2006).

As condições climáticas, como temperatura, umidade relativa do ar, direção e velocidade do vento e precipitação, exercem um efeito significativo tanto na ignição quanto na propagação dos incêndios florestais. Esses fatores afetam diretamente o teor de umidade do material combustível, o que pode facilitar o início do fogo. Além disso, a velocidade e a direção do vento são fatores críticos que influenciam nas estratégias de combate aos incêndios, pois indicam a taxa de propagação e a possível direção do fogo (SOARES, 1995).

Considerando ser um fator determinante do clima regional, a topografia também desempenha um papel importante na propagação do fogo. Embora seja um fator estático, o relevo influencia o comportamento dos ventos locais, bem como o clima ou microclima da região. Além disso, a cobertura vegetal ou o tipo de vegetação é uma característica fundamental a ser considerada. Vegetações mais densas tendem a manter um teor de umidade mais estável devido à criação de seu próprio microclima, enquanto vegetações mais esparsas estão mais sujeitas à perda de umidade e permitem uma maior circulação de ar, facilitando assim a propagação do fogo (VASCONCELOS e VENTURA, 2006).

Conforme destacado por Fernández et al. (2009), a atividade humana é atualmente o principal agente causador de incêndios florestais. Em áreas próximas a regiões densamente povoadas ou a infraestruturas como rodovias, ferrovias e áreas de recreação, a probabilidade de ignição aumenta consideravelmente devido à maior exposição a fontes de ignição decorrentes da negligência humana.

2.2.3 Correlação de Pearson

O coeficiente de correlação de Pearson é uma medida estatística que foi desenvolvida pelo matemático e estatístico Karl Pearson em conjunto com o cientista Francis Galton, no final do século XIX (STIGLER, 1989). Essa medida é utilizada para avaliar a intensidade e a direção da relação linear entre duas variáveis quantitativas (MOORE, 2007). Em outras palavras, o coeficiente de correlação de Pearson expressa o grau de associação linear existente entre duas variáveis.

A correlação de Pearson (r) pode ser calculado a partir da seguinte fórmula:

$$r = \frac{\left(\Sigma xy - \frac{(\Sigma x \Sigma y)}{n} \right)}{\sqrt{\left(\frac{\Sigma x^2 - (\Sigma x)^2}{n} \right) * \left(\frac{\Sigma y^2 - (\Sigma y)^2}{n} \right)}} \quad (22)$$

Onde:

- r é coeficiente de correlação de Pearson;
- Σxy é a soma dos produtos entre os desvios em relação às médias de x e y;

- Σx é a soma dos desvios em relação à média de x ;
- Σy é a soma dos desvios em relação à média de y ;
- Σx^2 é a soma dos quadrados dos desvios em relação à média de x ;
- Σy^2 é a soma dos quadrados dos desvios em relação à média de y ;
- n é o número de observações.

A variação da correlação ocorre entre -1 e +1. Um valor de r igual a +1 indica uma correlação perfeita e positiva entre as variáveis, ou seja, quando uma variável aumenta, a outra também aumenta na mesma proporção. Por outro lado, um valor de r igual a -1 indica uma correlação perfeita e negativa entre as variáveis, ou seja, quando uma variável aumenta, a outra diminui na mesma proporção. Quando r é igual a zero, não há correlação linear entre as variáveis. (FILHO et al., 2014)

2.2.4 Índice de Moran

Em certos espaços geográficos, é comum que variáveis apresentem padrões similares de distribuição, de modo que a presença de uma distribuição espacial específica de uma variável pode indicar a existência de padrões semelhantes de outras variáveis nesse mesmo espaço (LUZARDO et al., 2017).

O Índice de Moran é uma técnica de análise exploratória utilizada para identificar a estrutura de correlação espacial presente em dados georreferenciados. Essa técnica estatística é aplicada com o objetivo de estimar a magnitude da autocorrelação espacial entre as áreas, através da identificação da medida estatística mais adequada para descrever a covariância espacial presente nos dados (CÂMARA et al., 2002).

O Índice de Moran é aplicado, usualmente, em unidades de área às quais estejam associados atributos do tipo racional ou de intervalo (LONGLEY et al., 2005) e expressa a autocorrelação, considerando apenas o primeiro vizinho, ou seja, emprega a matriz de vizinhança de primeira ordem, independentemente do critério de composição da matriz $[W]$ escolhido. Usa-se esta expressão (Câmara et al., 2002):

O Índice de Moran é comumente aplicado em unidades de áreas que sejam associadas a uma escala racional ou de intervalo, utilizando-se a matriz vizinha de

primeira ordem para a análise espacial (LONGLEY et al., 2005). O cálculo do Índice de Moran Global (I) é realizado através da seguinte expressão matemática:

$$I = \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (z_i - \mu_z)(z_j - \mu_z)}{\sum_{i=1}^n (z_i - \mu_z)^2} \quad (23)$$

Onde:

- n é o número de áreas;
- z_i é o valor do atributo considerado na área i ;
- μ_z é o valor médio do atributo na região de estudo;
- w_{ij} é o elemento ij da matriz de vizinhança normalizada.

O resultado obtido pela equação de I é semelhante ao resultado obtido pela correlação linear de Pearson (COSTA NETO, 2002). Se houver uma correlação positiva dos dados, então a maioria dos polígonos vizinhos terá valores do mesmo lado da média, e o índice será positivo ($[I > 0]$), indicando uma correlação espacial direta. Por outro lado, se os dados se correlacionam negativamente, então a maioria dos polígonos vizinhos terá valores de atributos em lados opostos da média, e o índice será negativo ($[I < 0]$), indicando uma correlação espacial inversa. Quando o índice for igual a zero ($[I = 0]$), isso indica a ausência de correlação espacial (LUZARDO et al., 2017).

2.2 METODOLOGIA

2.2.1 Coleta dos dados

Para a realização do presente estudo, utilizaram-se dados obtidos por meio de fontes públicas na internet. Os pontos de calor da RECM foram obtidos a partir do Banco de Dados de Queimadas (BDQueimadas), gerenciado pelo Instituto Nacional de Pesquisas Espaciais (INPE). O BDQueimadas é um repositório de informações históricas acerca de focos de queimada detectados por satélites, que conta atualmente com um acervo de aproximadamente 250 milhões de pontos, desde o ano

de 1998. A coleta desses pontos se deu por meio de dez satélites distintos, dentre os quais se destacam oito satélites polares (NOAA-18, NOAA-19, NOAA-20, METOP-B, METOP-C, NASA TERRA e AQUA) e dois satélites geoestacionários (GOES-16 e MSG-3). Cabe ressaltar que todos esses satélites utilizam sensores óticos operando na faixa termal-média de 4um (INPE, 2022).

O desmatamento da RECM foi obtido por meio da plataforma web TerraBrasilis (Terrabrasilis,2022), desenvolvida pelo INPE. O TerraBrasilis é uma ferramenta de acesso, consulta, análise e compartilhamento de dados geográficos referentes ao monitoramento da vegetação nativa, seguindo os padrões internacionais de disseminação de dados geográficos e as especificações da Infraestrutura Nacional de Dados Espaciais (INDE). Tal plataforma é utilizada para disponibilizar informações geoespaciais confiáveis, atualizadas e de qualidade, visando subsidiar estudos, projetos e tomadas de decisão relacionadas ao meio ambiente

Os dados meteorológicos da RECM são cruciais para estudos que visam entender a dinâmica climática e suas implicações no ambiente e na sociedade. Para isso, os seguintes dados foram obtidos a partir da base de dados do programa NASA/POWER (NASA - Prediction of Worldwide Energy Resources) (NASA, 2022): temperatura (°C), pressão de superfície (KPa), umidade específica (g/kg), umidade relativa (%), direção do vento (°), velocidade do vento (m/s), umidade da superfície do solo (%), precipitação (mm/dia) e irradiação (W/m²).

Vale ressaltar que a plataforma NASA/POWER é caracterizada por sua abertura, cobertura espacial global e diferentes escalas temporais, incluindo mensal, diária e horária, o que a torna uma fonte essencial de informações para análises climáticas precisas e modelagem em diversas regiões do planeta.

As informações acerca da altimetria da Resex em questão foram adquiridas por meio do portal Brasil Relevo, que é mantido pela renomada Empresa Brasileira de Pesquisa Agropecuária (Embrapa). Essa fonte de dados se baseia nos registros obtidos pela nave espacial americana durante a missão SRTM (Shuttle Radar Topography Mission), os quais permitem obter medidas altimétricas precisas para cada área de 90 metros por 90 metros do território nacional. (BRASIL, 2022)

Para obter as informações do Índice de Vegetação por Diferença Normalizada (NDVI) da RECM, utilizou-se o Earth Explorer em conjunto com as cenas Landsat 8. Foram selecionadas imagens da RECM para o período entre os anos de 2009 a 2022.

As cenas foram disponibilizadas no formato tiff, com resolução de 16 bits, georreferenciadas e autorretificadas, sendo que cada imagem representa uma faixa do espectro captado pelo satélite.

2.2.2 Procedimentos preparatórios

Após a coleta dos dados, todas as informações referentes às variáveis foram organizadas em médias anuais e armazenadas em tabelas no formato xlsx. Para a realização da análise de comparação e interação entre as variáveis, tornou-se necessário normalizar os dados.

A normalização é uma técnica que permite que as variáveis sejam ajustadas para terem uma média igual a zero e um desvio padrão igual a um, garantindo que todas as variáveis tenham o mesmo peso na análise e que a escala de valores seja uniforme. Essa técnica é essencial para obter uma escala comum, sem distorcer as diferenças nos intervalos de valores, facilitando a comparação e interpretação dos resultados. Para realizar a normalização dos dados, utilizou-se a seguinte fórmula (Molion, 2005):

$$z = \frac{x - \mu}{\sigma} \quad (24)$$

Onde z é a variável normalizada; x é o valor anual da variável; μ é valor médio da variável no período, σ é o desvio padrão.

Os dados normalizados foram integrados em uma planilha no formato xlsx, visando a análise da correlação linear de Pearson das seguintes variáveis: focos de calor, desmatamento, temperatura, pressão de superfície, umidade específica, umidade relativa, direção do vento, velocidade do vento, umidade da superfície do solo, precipitação e irradiação.

Os dados geoespaciais referentes às variáveis focos de calor (un), desmatamento (há), altitude do terreno (m), distância para cursos de água (m), distância de ramais internos (m), distância de rodovias (m) e Índice de Vegetação da Diferença Normalizada (NVDI) na RECM foram consolidados através do emprego do software livre Qgis 3.16.14, seguindo a malha da Reserva e sendo divididos em grades de tamanho 1 x 1 km. Posteriormente, foram salvos em arquivos no formato shapefile.

2.2.3 Avaliação das variáveis

Com a base de dados preparada, utilizou-se o software Excel para elaborar e verificar o comportamento da série temporal de focos de calor e desmatamento, bem como para examinar a frequência dos focos de calor na RECM.

Para estimar a densidade do padrão de distribuição dos focos de calor, empregou-se o software livre Qgis 3.16.14 e a ferramenta "Mapa de calor (Estimativa de densidade Kernel)" com um raio de 5 quilômetros. Essa análise foi realizada a partir das camadas pontuais reprojatadas para o sistema de coordenadas UTM, SIRGAS 2000, EPSG: 4674, permitindo a geração de um mapa de proporção de incêndios dentro da área de estudo.

O Modelo Espacial de Kernel é uma técnica estatística amplamente utilizada para estimar a distribuição espacial de eventos ou ocorrências, tais como os focos de calor, por meio da produção de uma superfície de densidade de pontos por unidade de área. Essa abordagem permite identificar aglomerações espaciais, também conhecidas como "áreas quentes" ou "hotspots" (FREIRE, 2012). A presença de uma "área quente" indica uma concentração de eventos em uma determinada região, podendo ser utilizada para identificar áreas de maior risco ou que necessitam de intervenções (SANT'ANA et al., 2014). A seguinte equação é utilizada para calcular a densidade de Kernel:

$$f_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{X - X_i}{h}\right) \quad (25)$$

Onde

- K é a função de Kernel escolhida;
- h é o raio em torno do ponto analisado,
- X é a posição central da célula do raster de saída,
- X_i é a posição do ponto i proveniente do centróide de cada polígono e n é o número total de pontos.

A utilização do Modelo espacial de Kernel permite a geração de mapas de densidade de pontos, conhecidos como "áreas quentes" ou "hotspots", que são

indicativos de concentrações de eventos em uma distribuição espacial (FREIRE, 2012; SANT'ANA et al., 2014; OLIVEIRA et al., 2017).

Com o arquivo da base de dados normalizada, utilizou-se do software livre R Studio 4.2.3, juntamente com o pacote corrplot, para realizar a análise de correlação linear de Pearson. Essa técnica proporcionou a obtenção de uma matriz de correlação, cuja ordenação automática das variáveis contribuiu para a detecção de padrões ocultos entre elas.

Ademais, para a análise das correlações geoespaciais, utilizou-se o software livre Geoda, o qual permitiu a visualização espacial das variáveis por meio de mapas, possibilitando a análise do padrão espacial do fenômeno em questão. Nesse sentido, optou-se pela utilização da matriz do tipo rainha com grande nível 1, visando garantir uma maior precisão e confiabilidade dos resultados obtidos.

2.3 RESULTADOS E DISCUSSÃO

2.3.1 Evolução de focos de calor

A partir dos dados coletados, verificou-se um total de 12765 focos de calor na Reserva Extrativista Chico Mendes (RECM) em 2021, sendo este o período com o maior número de ocorrências registradas no estudo. Como ilustrado na Figura 10, observou-se uma tendência de aumento significativo no número de focos de calor ao longo dos anos, com um crescimento de 4432% quando comparado o período de 2002 com o de 2021.




Figura 10 - Evolução da taxa de focos de queimadas na Reserva Extrativista Chico Mendes entre os anos de 2002 -2021

Fonte: INPE (2022)

A partir de 2015, houve uma tendência crescente, com uma leve queda em 2018, mas com uma intensificação dos números de focos de calor na RECM, nunca presenciada na reserva.

Em 2005, ocorreram grandes incêndios florestais dentro da RECM, gerando preocupação entre a população e a gestão da reserva quanto à utilização e prevenção de queimadas (MASCARENHAS et al., 2018). Em 2008, foi realizada uma revisão do Plano de Utilização da Resex, incluindo medidas preventivas como a estipulação de períodos para queimadas, distância mínima para aceiros, criação de mutirões e responsabilização dos moradores pelas colocações de incêndios (BRASIL, 2008). Essa revisão no plano de utilização pode ter sido o elemento estabilizador do número de focos de calor dentro da Resex entre os períodos de 2008 e 2011.

Com a eleição do governo Bolsonaro em 2018, a ideologia da política ambiental no Brasil sofreu mudanças significativas, com o enfraquecimento de órgãos de fiscalização e uma redução de ações contra atividades ilegais em terras públicas. Isso resultou em um aumento de 56% do desmatamento no bioma Amazônico entre 2018 e 2022, a maioria em terras da União (GARRIDO, 2022). A tendência de aumento de focos de calor na RECM a partir de 2018 pode ser um reflexo dessas mudanças nas políticas públicas relacionadas à preservação ambiental.

A análise da frequência dos focos de calor dentro da RESEX (Figura 11) revelou um padrão recorrente, com o mês de julho sendo o início do período de ocorrências, estendendo-se até novembro, e o mês de setembro sendo o pico de ocorrências em todos os anos analisados no estudo

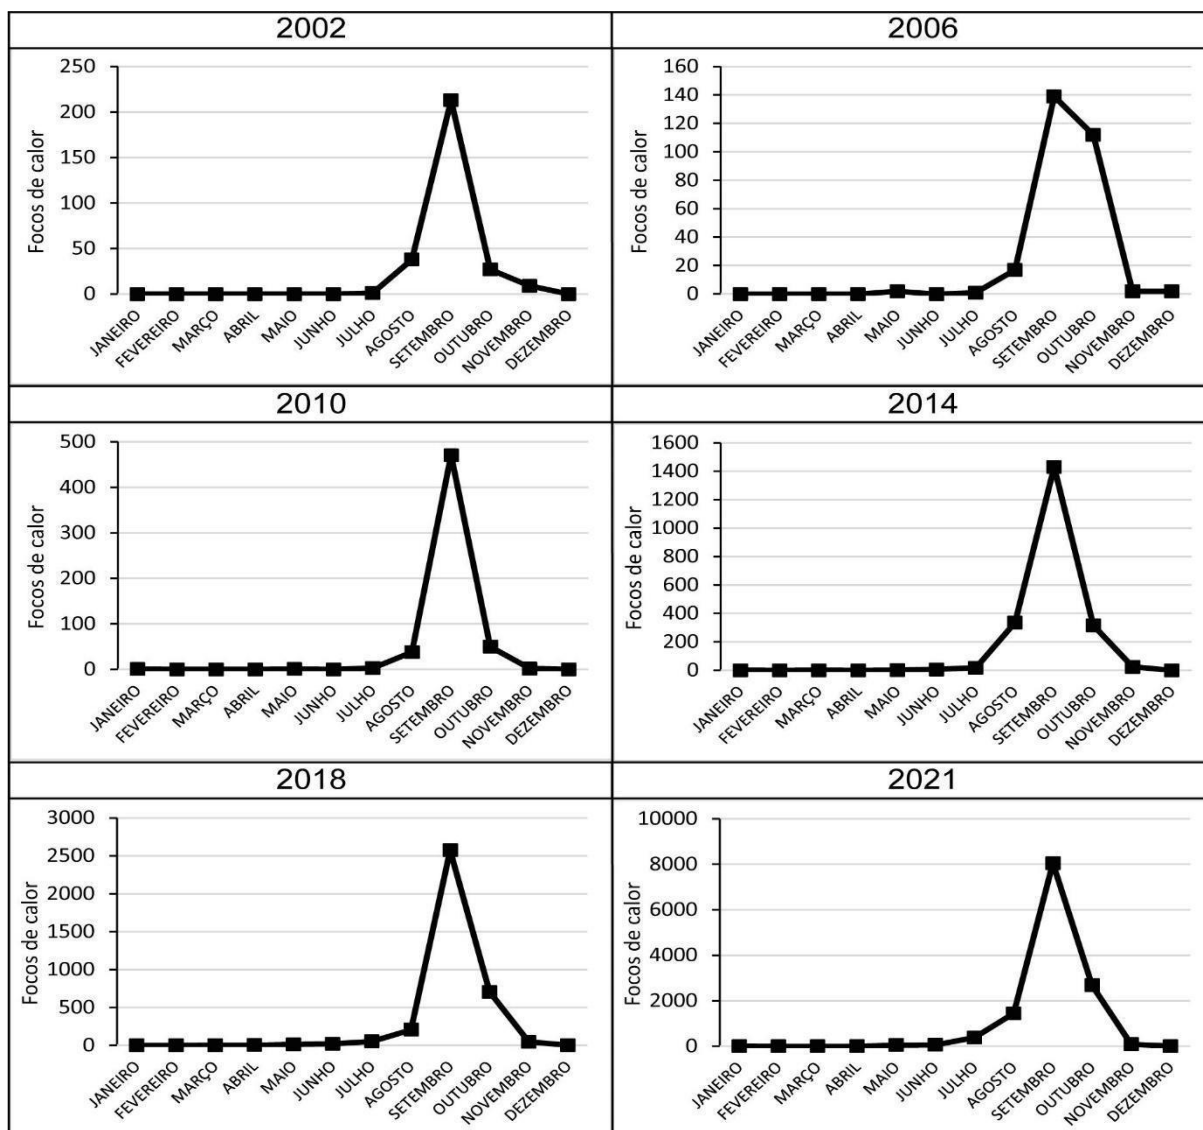


Figura 11 - Frequência dos focos de queimada no RECM. (A) 2002; (B) 2006; (C) 2010; (D) 2014; (E) 2018; e (F) 2021.
Fonte: INEP (2022)

A análise dos dados coletados sobre a evolução histórica dos focos de queimadas na revelou um aumento significativo no número de focos de calor, sendo o ano de 2021 o ano com o maior número de focos detectados. A figura 12 ilustra a quantidade de focos de calor detectados durante os anos de 2002 a 2021.

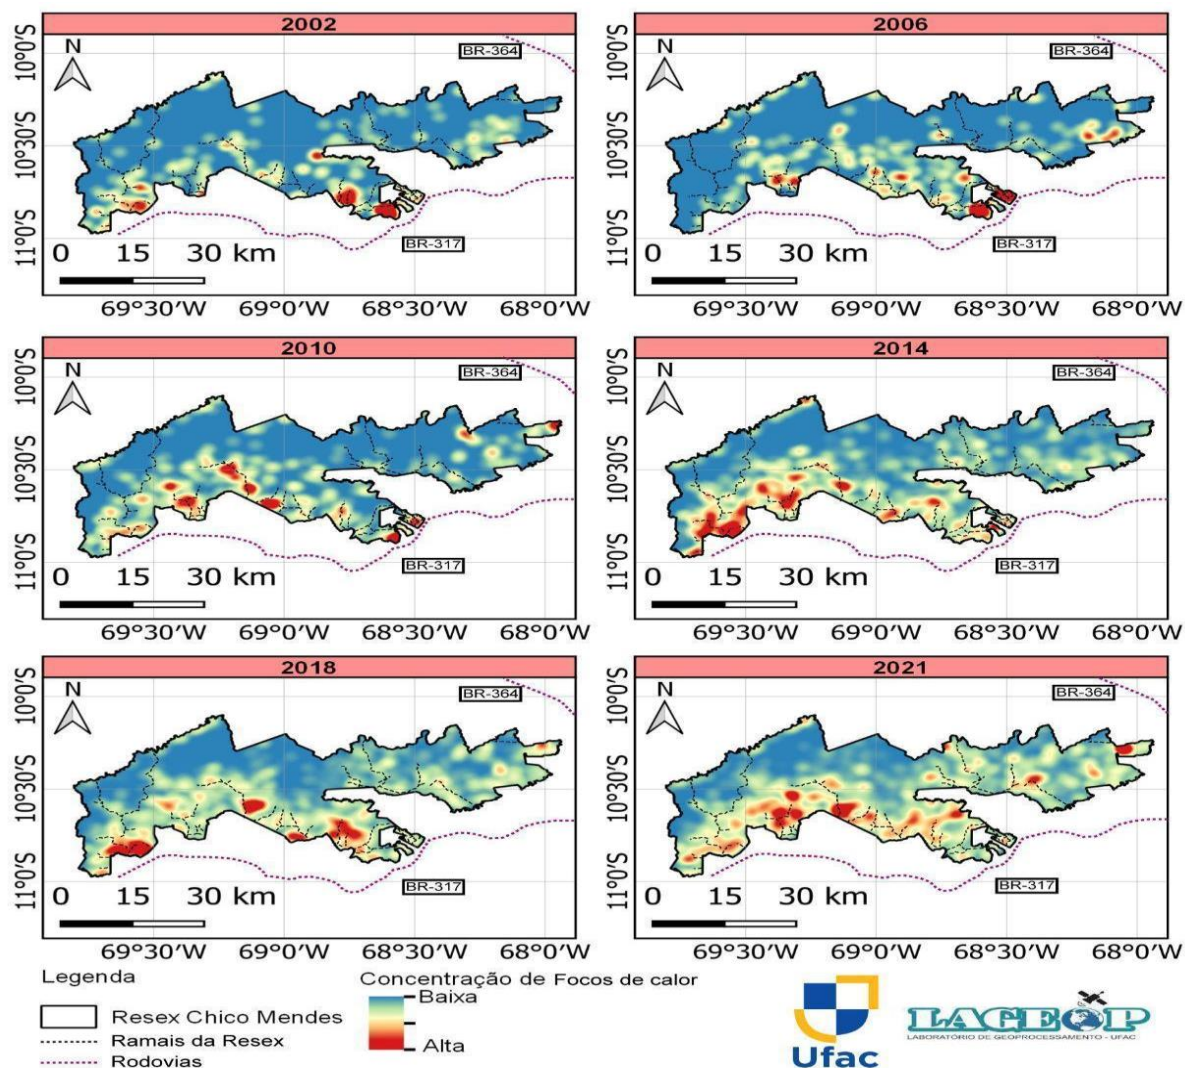


Figura 12 - Evolução da concentração de focos de calor na RECM entre 2002 a 2021.
Fonte: INEP (2022)

A análise dos dados indica que a região sul da RESEX é a que apresenta a maior ocorrência de focos de calor, sendo que atualmente é possível observar focos de queimadas em quase a totalidade da reserva. Além disso, a análise dos dados também revelou uma relação entre a proximidade das rodovias e o aumento dos focos de queimadas. As regiões ao sul da reserva são as mais próximas da BR-317, e nestas é onde a aglomeração de focos de calor é predominante historicamente. Já a região leste, que se encontra próxima da BR-364, também tem apresentado um aumento significativo no número de focos de calor ao longo dos anos. Por outro lado, a região norte da reserva, que não tem contato próximo com nenhuma das principais rodovias do estado do Acre, é a área com menor número de focos de calor.

Os resultados desta análise indicam que é necessário implementar medidas preventivas para o controle dos incêndios florestais na RESEX, bem como a monitoramento contínuo das áreas próximas às rodovias para identificar e prevenir a ocorrência de focos de calor. Além disso, é importante considerar as mudanças na política ambiental do país e sua possível influência no aumento dos focos de calor na reserva.

A análise da evolução histórica dos focos de queimadas na Reserva Extrativista Chico Mendes (RECM) revela um crescente aumento preocupante, como evidenciado na Figura 6. A região sul da reserva apresenta uma utilização histórica elevada do fogo, com a presença de focos de queimadas em quase toda a área da RESEX.

A relação entre a proximidade das rodovias e o aumento de queimadas também é evidente ao analisar a evolução dos focos de queimadas na RECM. As regiões ao sul da reserva estão próximas à BR-317 e apresentam uma aglomeração histórica de focos. Já a região leste, que se encontra próxima à BR-364, tem apresentado um crescente aumento no número de focos nos últimos anos. Por outro lado, a região norte da RECM, que não possui contato próximo com nenhuma das principais rodovias do estado do Acre, apresenta o menor número de focos de calor da RESEX.

A construção de estradas é um elemento histórico do desmatamento e das queimadas na Amazônia (Carvalho et al., 2001). A consolidação de uma estrada reduz o custo de transporte, o que incentiva a intensificação das atividades agropecuárias e consequentemente, leva a transformações na paisagem, como o aumento de queimadas e desmatamento (Margulis, 2001).

A Figura 13 apresenta a variação das classes de densidade dos focos de calor com os valores de desmatamento. A partir de 2014, houve um aumento significativo na densidade em todas as classes, com o ano de 2021 apresentando o maior número de focos registrados na RESEX até então, com um crescimento aproximado de 1780% em densidade em comparação com o ano de 2002.




Figura 13 - Variação das classes de densidade dos focos de calor na RECM entre 2002 a 2021.
Fonte: INPE (2022)

2.3.2 Relação focos de calor e desmatamento

A Figura 14 destaca a expansão contínua da área desmatada na RECM ao longo do tempo. Notavelmente, essa tendência de aumento da área desmatada está em consonância com a evolução temporal da quantidade de focos de calor dentro da RESEX.




Figura 14 - Evolução do desmatamento na Reserva Extrativista Chico Mendes entre os anos de 2002 -2021
Fonte: TerraBrasilis (2022) e Acre (2010).

A Figura 15 ilustra a dinâmica temporal dos eventos de queimadas na Área 1 da RECM, localizada nas coordenadas UTM Zona 19, latitude 10°22'39.04"S e longitude 68° 9'13.25"O. A imagem da Figura 14A, data de 10 de junho de 2003, apresenta a floresta original antes do registro do foco de incêndio no dia 02 de setembro de 2013 (dados do Programa Queimadas do INPE). A Figura 14B, data de 28 de julho de 2013, evidencia a realização de desmatamento florestal antes da utilização do fogo como instrumento de limpeza. Já a Figura 14C, mostra a consolidação da área para as práticas agropecuárias.

É importante destacar que a Amazônia tem apresentado crescentes níveis de desmatamento desde 1991, com as atividades de criação de gado, principalmente de médio e grande porte, sendo responsáveis por 70% do desmatamento na região (Fearnside, 2005).




Figura 15 - Sequência de fatos ocorridos antes e depois do foco localizado nas coordenadas UTM Zona 19, latitude 10°22'39.04"S e Longitude 68° 9'13.25"O: A:12/1985; B. 6/2013; C. 7/2013; D. 04/2021.
Fonte: Adaptado de Google Earth (2022).

De acordo com Maciel (2021), o declínio das atividades extrativistas como fonte de renda para as famílias dentro da RECM tem levado ao crescimento da pecuária como a principal atividade econômica, o que tem resultado em um aumento proporcional no desmatamento e queimadas na área. A Figura 16 ilustra como essa transformação de uso do solo tem ocorrido em diversos pontos da RESEX.

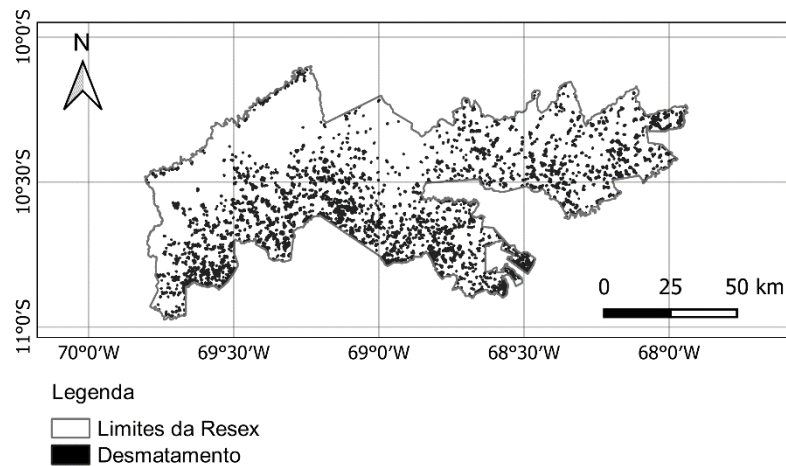


Figura 16 - Desmatamento da Reserva Extrativista Chico Mendes.
Fonte: Terrabrasilis (2022).

Além disso, a análise da sobreposição entre desmatamento e densidade de focos de calor na RECM entre 2002 e 2021 (Figura 17) revela uma forte relação entre essas duas variáveis. 55% da área desmatada está presente na classe de densidade de focos de calor "Alta", 39% estão na classe "Média" e 6% está na classe "Baixa". Isso sugere que as regiões com maior densidade de focos de calor também são as regiões com as maiores áreas desmatadas

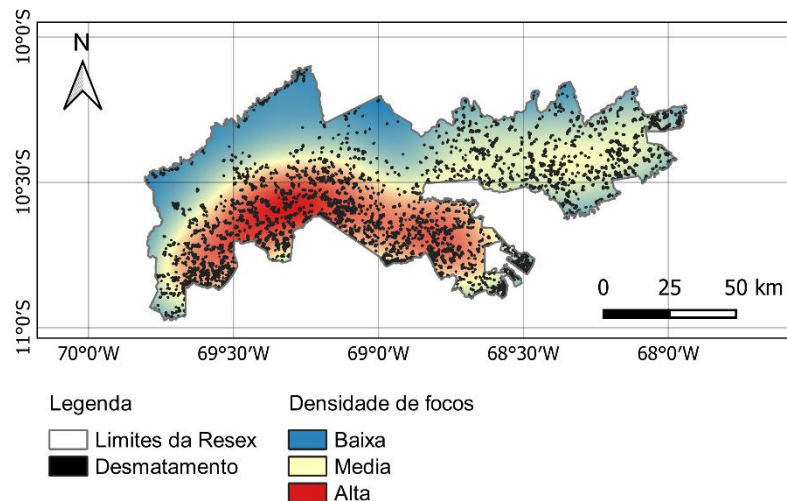


Figura 18 - Sobreposição da densidade de focos de calor com o desmatamento da Reserva Extrativista Chico Mendes entre os anos de 2002 a 2021.

Fonte: Terrabrasilis (2022) e INPE (2022)




Figura 17 - Relação entre área desmatada (km²) e classes de densidade de focos de calor na Reserva Extrativista Chico Mendes.

Fonte: Terrabrasilis (2022) e INPE (2022).

A soma das áreas desmatadas presentes nas classes de densidade "Alta" e "Média" é de 10.572,33 km², o que representa 94% do desmatamento total na RESEX, reforçando a relação entre desmatamento e focos de calor. Além disso, é importante destacar que o desmatamento também leva à fragmentação da floresta, tornando-a menos densa, menos úmida e mais suscetível a incêndios florestais, facilitando o início de queimadas que avançam e marcam novos limites dentro da floresta (COPERTINO et. al, 2019).

2.3.3 Correlação de variáveis

A figura 19 apresenta a variação das variáveis da RESEX no recorte temporal utilizado no estudo de 2002 a 2021.

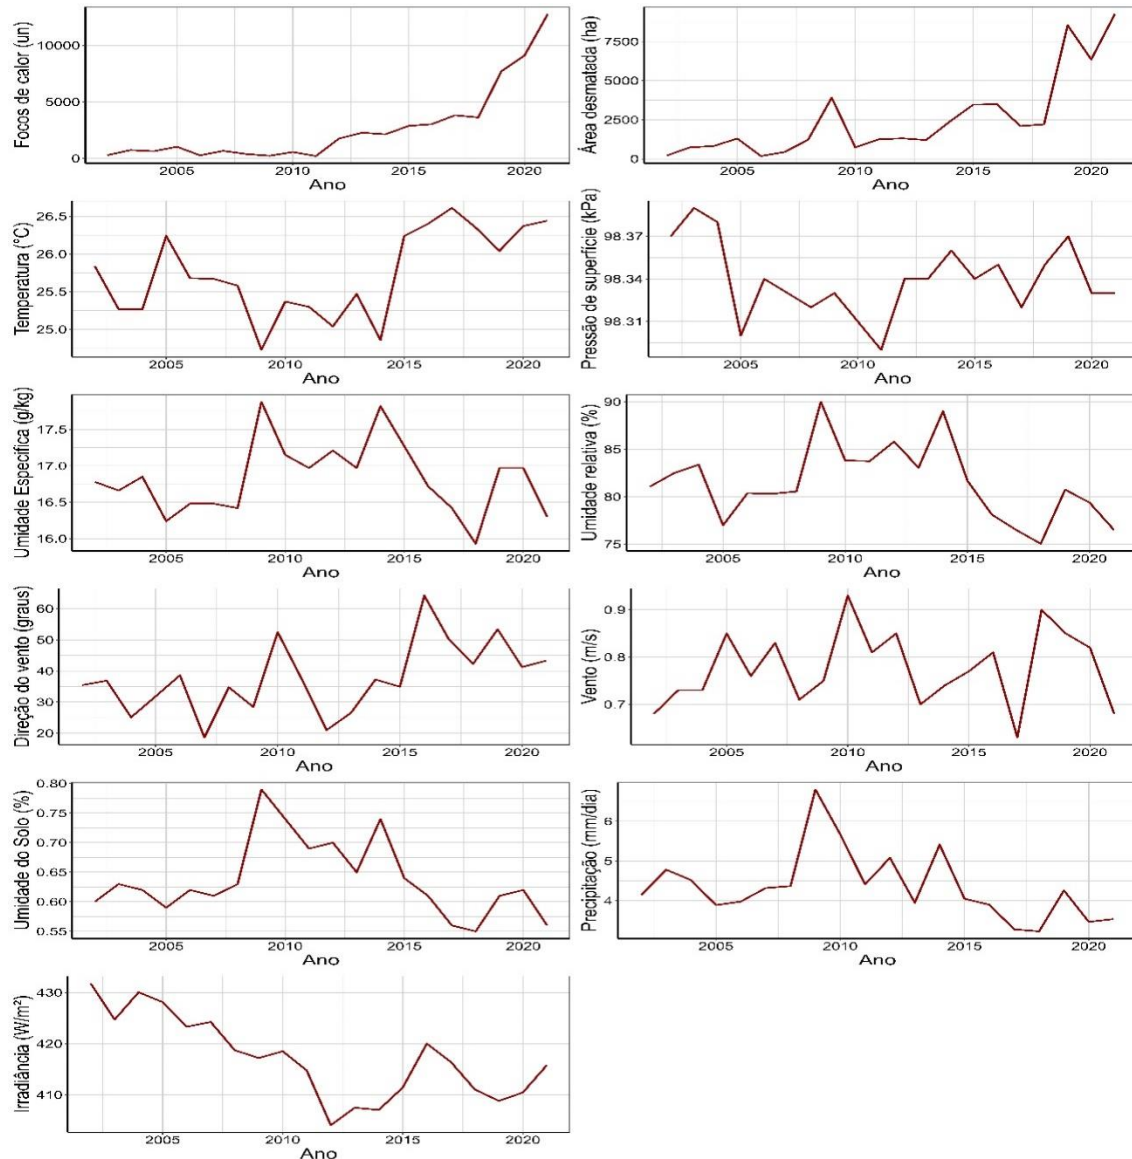


Figura 19 - Variação média das variáveis da RECM TerraBrasilis (2022), INPE (2022) e (NASA, 2022)

A matriz de correlação linear de Pearson nos apresenta as análises realizadas nas variáveis. (Figura 20). Ao considerar os focos de calor como ponto de referência, a análise indica que a área de desmatamento apresentou uma correlação muito forte com esse fenômeno. Além disso, as variáveis temperatura e direção também demonstraram uma correlação forte com os focos de calor. Por outro lado, observou-

se uma correlação inversa entre os focos de calor e as variáveis umidade relativa, umidade do solo, precipitação e irradiação

É interessante destacar que a pressão de superfície, umidade específica e vento não demonstraram correlação com os focos de calor.

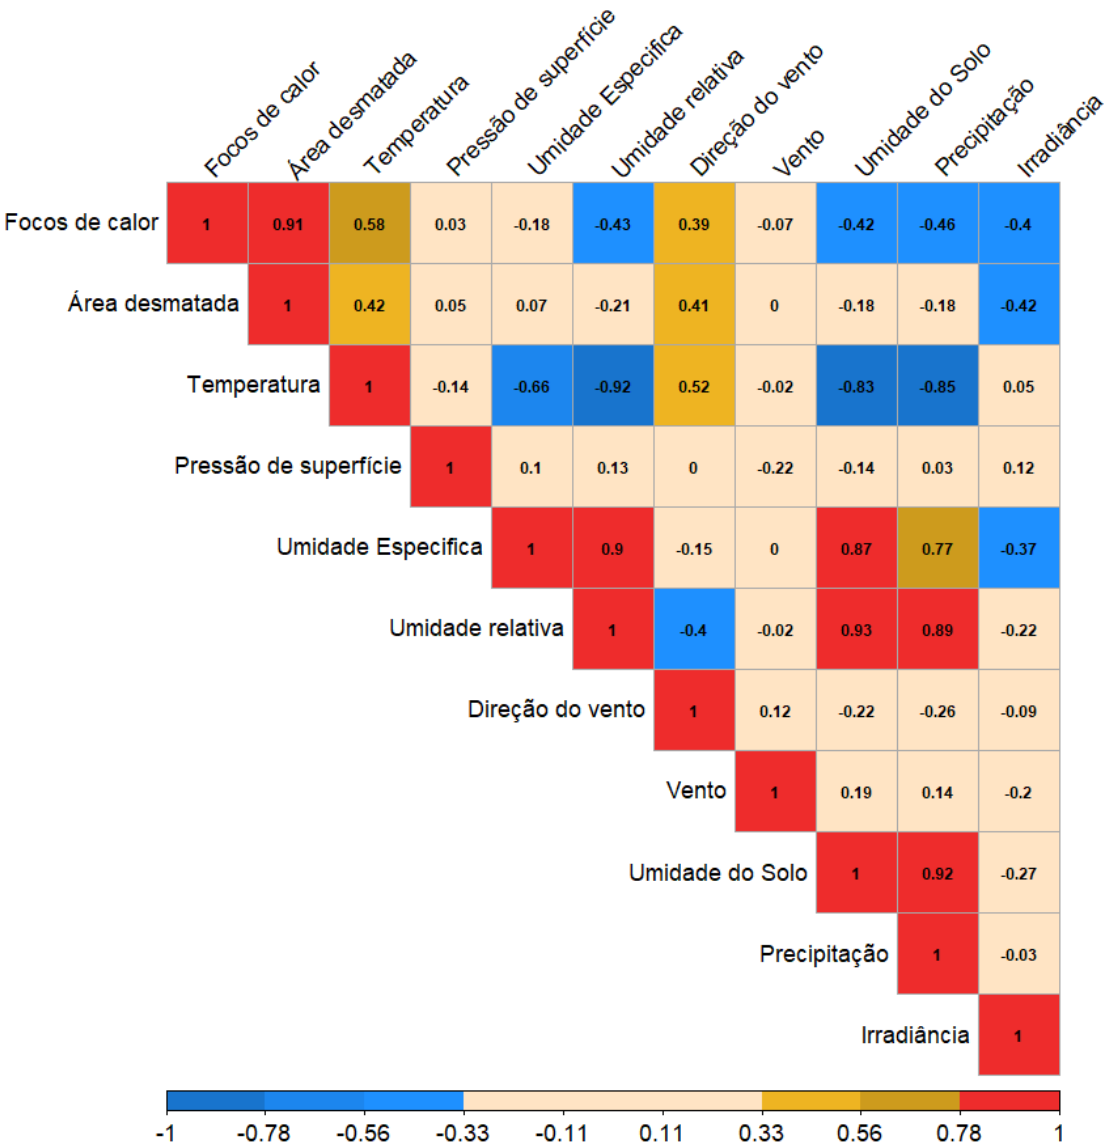


Figura 20 – Matriz de correlação de correlação linear de Pearson TerraBrasilis (2022), INPE (2022) e (NASA, 2022)

O cálculo do Índice de Moran foi realizado como parte da análise da variável focos de calor para cada ano. Os resultados correspondentes estão apresentados na Tabela 1, exibindo os valores do Índice de Moran obtidos para as variáveis analisadas.

Tabela 1 - Resultados do Índice de Moran Global para as variáveis analisadas.

VARIÁVEIS	Índice de Moran					
	2002	2006	2010	2014	2018	2021
Área desmatada	0.028	0.006	-0.039	-0.084	0.055	0.022
Altitude	0.032	-0.133	0.138	0.302	0.174	0.151
Distância de curso de água	0	0.05	0.003	-0.037	-0.008	-0.001
Distância de ramais	-0.24	-0.169	-0.244	-0.392	-0.381	-0.382
Distância de rodovias	-0.44	-0.366	-0.432	-0.556	-0.547	-0.478
NVDI	0.032	-0.098	-0.169	-0.021	-0.153	-0.061

Com base nos resultados obtidos, foi possível utilizar o Índice de Moran para detectar a presença de correlação espacial significativa entre a variável focos de calor e outras variáveis, como altitude, distância de ramais e rodovias. No entanto, ao contrário do índice de correlação de Pearson, o Índice de Moran não identificou uma correlação significativa entre os focos de calor e a área desmatada.

2.4 CONCLUSÃO

A criação de Reservas Extrativistas pode ser considerada uma medida otimista e visionária para alcançar o equilíbrio entre o desenvolvimento humano e a conservação da biodiversidade.

Essas áreas foram criadas como resultado da luta dos povos extrativistas contra a expansão agropecuária, visando implementar um modelo de uso dos recursos naturais que fosse sustentável, ecológico e economicamente eficiente.

No entanto, na situação da Reserva Extrativista Chico Mendes, o aumento do número de focos de calor dentro da reserva é um indicador de modificações nas atividades realizadas dentro da área, que vão de encontro aos princípios idealizados na concepção das RESEX.

Foi constatado um aumento significativo na incidência de fogo em áreas da RECM, com concentração especialmente nas regiões sul e leste. Além disso, foi possível identificar uma relação entre a concentração de áreas desmatadas e a ocorrência de focos de calor.

Ao analisar as correlações entre as variáveis precursoras do fogo, verificou-se, por meio do índice de correlação de Pearson, que a área desmatada apresentou uma

forte correlação com os focos de calor. Por outro lado, fatores como temperatura, direção do vento, umidade relativa, umidade do solo, precipitação e irradiação também apresentaram uma correlação significativa com a ocorrência de fogo na Resex.

No que se refere à análise geoespacial, observou-se, por meio do Índice de Moran, a presença de correlação espacial significativa entre focos de calor e outras variáveis, como altitude, distância de ramais e rodovias dentro da RECM.

Conclui-se, a partir dos resultados obtidos, que a área desmatada é um fator-chave para a ocorrência de focos de calor, embora outras variáveis ambientais também possam ter um papel significativo nesse contexto. Os aumentos expressivos na incidência de focos de calor e desmatamento na Resex sugerem um aumento preocupante das atividades exploratórias dos recursos naturais em um ambiente que deveria ser um exemplo de utilização sustentável.

Diante desse cenário, torna-se essencial realizar pesquisas adicionais para compreender as interações complexas entre as variáveis ambientais e implementar medidas efetivas de prevenção e controle de fogo na RECM e em outras regiões afetadas. A proteção dessas áreas, por meio da adoção de práticas sustentáveis, é fundamental para garantir a conservação da biodiversidade e o bem-estar das comunidades que dependem desses recursos naturais.

CAPÍTULO 3 - PREDIÇÃO DE ZONAS PROPENSAS A FOCOS DE CALOR NA RESERVA EXTRATIVISTA CHICO MENDES POR MEIO DE REDE NEURAL ARTIFICIAL

3.1 INTRODUÇÃO

A Amazônia abriga a maior floresta tropical contínua do mundo, desempenhando um papel crucial na regulação do clima global. No entanto, a ação do fogo nas florestas apresenta-se como um desafio urgente nesta região. Quando não controlado, o fogo exerce efeitos devastadores, acarretando danos significativos à biodiversidade, ao meio ambiente e às comunidades locais. No ano de 2022, o Brasil testemunhou uma perda alarmante de 16,3 milhões de hectares de floresta em virtude de atividades propulsoras do fogo (MONITCHELE, 2023), equivalente a áreas territoriais de países europeus como Portugal, Islândia e Inglaterra.

Esses dados alarmantes evidenciam a magnitude dessa problemática e destacam a necessidade imperativa de implementar medidas efetivas para abordar os incêndios florestais na Amazônia. A destruição de uma extensão tão vasta de floresta tropical não apenas resulta em perdas irreparáveis em termos de biodiversidade, mas também contribui para o agravamento das mudanças climáticas em escala global.

No estado do Acre, a Reserva Extrativista Chico Mendes é amplamente considerada a área mais ameaçada por desmatamento e queimadas (IMAZON, 2022), registrando sempre altos níveis de focos de calor com 12765 focos em 2022, 42% a mais do que em 2021 (INPE, 2023), resultando na perda de 9253 km² de floresta na reserva (TERRABRASILIS, 2023)

Devido à magnitude dos impactos causados pelo fogo, é crucial encontrar métodos eficazes para prevenção e gerenciamento de áreas de risco. Com o avanço da capacidade computacional, a inteligência artificial tem sido amplamente utilizada como um modelo eficaz de predição em diversas áreas, como por exemplo preços madeireiros (LOPES et al, 2021), deslizamento de terra (LIU et al, 2022), classificação de espécies (PARQUE et al, 2022) e estimativa de biomassa (MORADI et al, 2022).

As Redes Neurais Artificiais (RNA's) são formas de inteligência artificial que se baseiam em modelos neurobiológicos da rede neural humana. Elas são projetadas

para resolver problemas de aprendizado de máquina e imitar a capacidade da rede neural humana de aprender e tomar decisões com base em dados (HAYKIN, 2001),

O objetivo deste capítulo é desenvolver uma Rede Neural Artificial capaz de prever a ocorrência de focos de calor na Reserva Extrativista Chico Mendes. Os principais objetivos desta pesquisa são: (1) prever as zonas de ocorrência de focos de calor em áreas da RECM e (2) avaliar o desempenho da Rede Neural Artificial a fim de obter um modelo confiável.

A implementação dessa tecnologia proporcionará uma resposta mais rápida e eficiente diante de situações de emergência, contribuindo significativamente para a preservação da floresta e a proteção da biodiversidade local. Ao prever as zonas de ocorrência de focos de calor, será possível antecipar e adotar medidas preventivas, como o reforço da fiscalização e a implementação de estratégias de combate aos incêndios.

3.2 MATERIAIS E MÉTODOS

3.2.1 Coleta de dados

Para a realização do presente estudo, foram empregados dados de entrada que abrangem um período temporal de cinco anos, compreendendo o intervalo de 2016 a 2020, sendo que os dados relativos ao ano de 2020 foram empregados na validação do modelo proposto. Para a aquisição das informações necessárias, recorreu-se à obtenção de dados provenientes de fontes de acesso público disponíveis na internet.

Os dados de focos de calor foram adquiridos a partir do Banco de Dados de Queimadas (BDQueimadas), gerenciado pelo Instituto Nacional de Pesquisas Espaciais (INPE). O BDQueimadas é um repositório de informações históricas acerca de focos de queimada detectados por satélites, que conta atualmente com um acervo de aproximadamente 250 milhões de pontos, desde o ano de 1998. Considerou-se para as análises informação de dez satélites distintos, dentre os quais se destacam oito satélites polares (NOAA-18, NOAA-19, NOAA-20, METOP-B, METOP-C, NASA TERRA e AQUA) e dois satélites geoestacionários (GOES-16 e MSG-3). Cabe

ressaltar que todos esses satélites utilizam sensores ópticos operando na faixa termal-média de 4 μ m (INPE, 2022).

O desmatamento foi obtido por meio da plataforma web TerraBrasilis (TerraBrasilis, 2022), desenvolvida pelo INPE. O TerraBrasilis é uma ferramenta de acesso, consulta, análise e compartilhamento de dados geográficos referentes ao monitoramento da vegetação nativa, seguindo os padrões internacionais de disseminação de dados geográficos e as especificações da Infraestrutura Nacional de Dados Espaciais (INDE). Tal plataforma é utilizada para disponibilizar informações geoespaciais confiáveis, atualizadas e de qualidade, visando subsidiar estudos, projetos e tomadas de decisão relacionadas ao meio ambiente

Dados meteorológicos são cruciais para estudos que visam entender a dinâmica climática e suas implicações no ambiente e na sociedade. Para isso, os seguintes dados foram obtidos a partir da base de dados do programa Prediction of Worldwide Energy Resources – POWER (NASA, 2022): direção do vento em graus, precipitação (mm/dia), radiação (MJ/m²), temperatura (°C), umidade específica e umidade relativa (%).

Os dados relativos às rodovias federais foram adquiridos por meio do portal oficial do Ministério dos Transportes. Por outro lado, as informações concernentes às rotas internas da RECM foram obtidas através do Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio) (BRASIL 2022).

Informações sobre topografia da Resex foram adquiridas por meio do portal Brasil Relevo, que é mantido pela renomada Empresa Brasileira de Pesquisa Agropecuária (Embrapa). Essa fonte de dados se baseia nos registros obtidos pela nave espacial americana durante a missão SRTM (Shuttle Radar Topography Mission), a qual permite obter medidas altimétricas precisas para cada área de 90 metros por 90 metros do território nacional (BRASIL, 2022)..

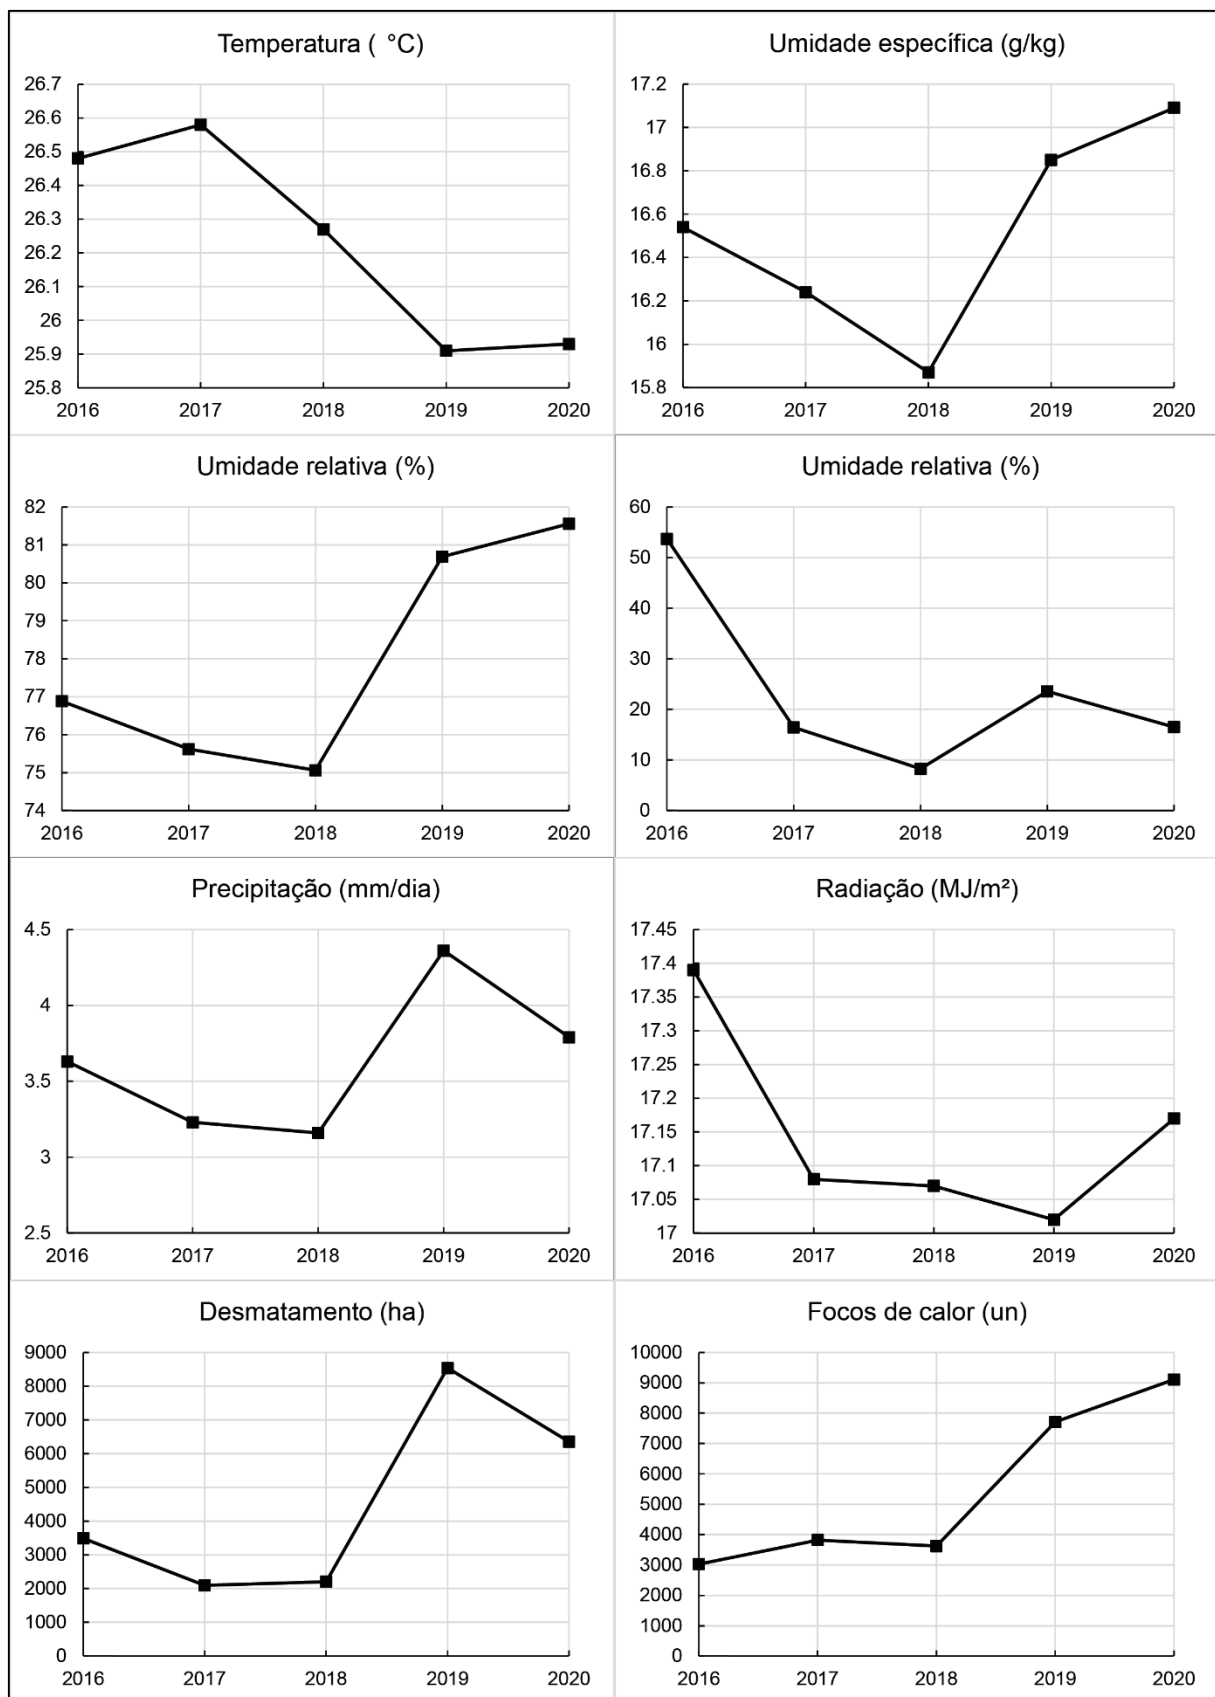


Figura 21 - Médias anuais das variáveis metrológicas.
Fonte: Própria (2023)

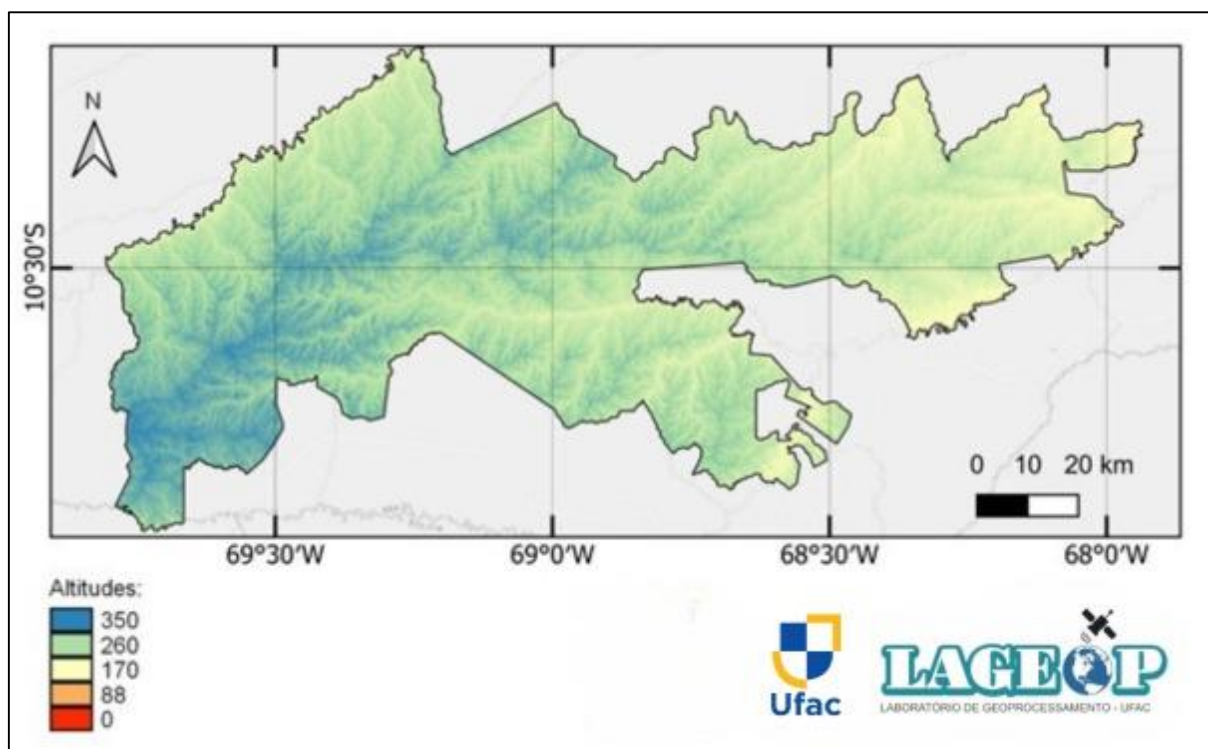


Figura 23 - Topografia da RECM
Fonte: Própria (2023)

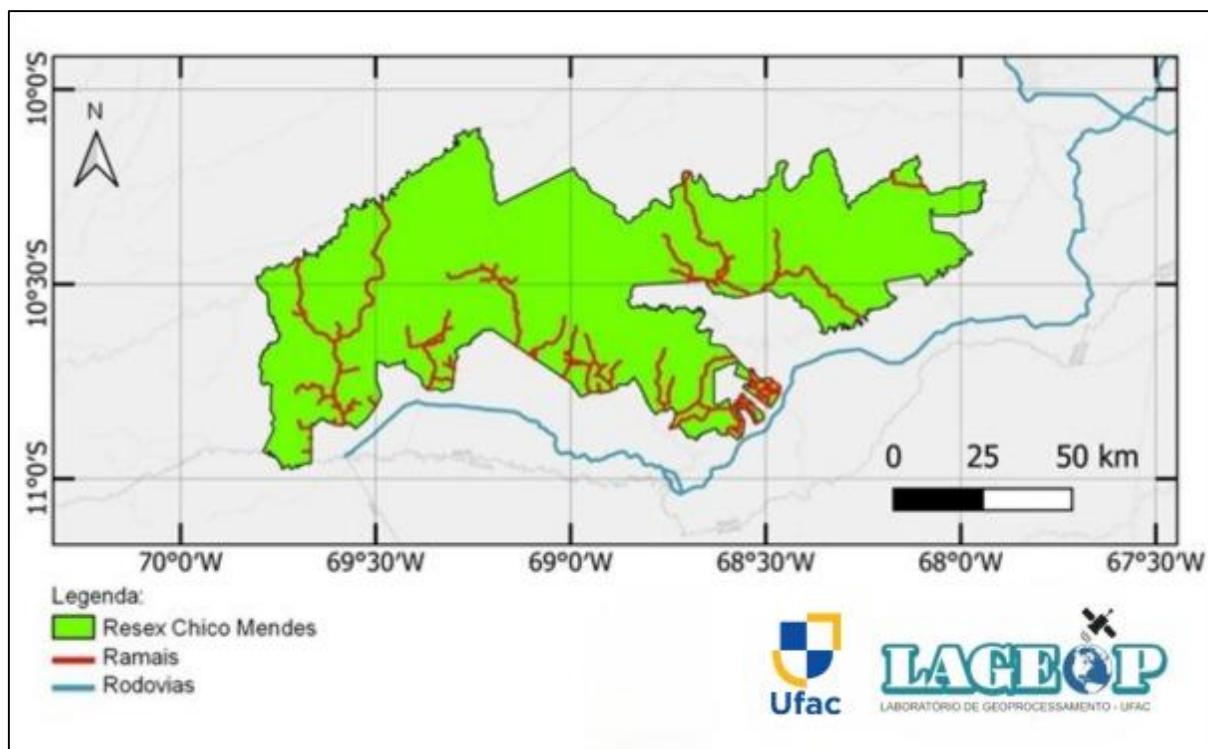


Figura 22 - Ramais internos da RECM é rodovias próximas.
Fonte: Própria (2023)

3.2.2 Preparação dos dados

O modelo foi validado utilizando as informações de focos de calor como dados de saída. Para a construção da rede foi considerado os dados de entrada como sendo o período temporal de 4 anos (2016 a 2019), sendo os dados referentes ao ano de 2020 utilizados para a validação do modelo. Para isto, os dados de entrada foram vetorizados e separados em conjuntos de treinamento e validação da RNA, e o modelo foi validado por comparação com os dados de 2020.

Após a conclusão da fase de coleta de dados, dez variáveis foram organizadas para o processo de modelagem, sendo elas: altitude (m), distância de ramais da RECM (m), distância de rodovias para a RECM (m), desmatamento (ha), direção do vento (°), precipitação (mm/dia), radiação (MJ/m²), temperatura (°C), umidade específica e umidade relativa (%). As variáveis meteorológicas foram compiladas em médias anuais e registradas em tabelas no formato xlsx. Em seguida, os dados foram submetidos a uma abordagem de interpolação geoestatística utilizando o software QGIS 3.16.14, empregando o método de krigagem para estimar os valores das variáveis dentro da RECM.

A krigagem é um método geoestatístico de interpolação que desempenha um papel fundamental na estimativa e predição de superfícies em problemas de análise espacial. Essa abordagem se baseia em uma estrutura de correlação espacial para fornecer estimativas não tendenciosas e de variâncias mínimas. Em outras palavras, a krigagem busca obter estimadores que sejam imparciais, ou seja, a diferença entre os valores estimados e os observados no mesmo local não deve ser nula. Além disso, a krigagem procura minimizar a variância desses estimadores, garantindo que eles possuam a menor variância possível entre todos os estimadores não tendenciosos disponíveis (DRUCK et al., 2004).

As variáveis que abrangem as distâncias entre as rodovias e os ramais em relação aos focos de calor foram submetidas ao cálculo da distância euclidiana. Esse procedimento permitiu determinar a distância em metros entre os focos de calor e as rodovias, bem como os ramais. Para realizar o cálculo da distância euclidiana, empregou-se a ferramenta "r.grow.distance" disponível no software QGIS 3.16.14.

Uma técnica de transformação foi empregada na variável relacionada aos focos de calor, convertendo-a em uma variável binária (dummy). Os dados referentes aos

focos de calor foram categorizados como (0) para denotar a ausência de incêndios e (1) para indicar a presença de incêndios. Da mesma forma, essa abordagem foi aplicada à variável relacionada ao desmatamento.

Após a coleta e organização, todos os dados meteorológicos e informações concernentes à altitude, distâncias de ramais e rodovias, bem como dados sobre o desmatamento e focos de calor na RECM, foram submetidos a um processo de organização, resultando em uma grade interna com uma resolução de 1 x 1 km, compreendendo um total de 10.545 células (Figura 23). Estes dados foram armazenados em arquivos no formato shapefile. Essa abordagem de consolidação dos dados em uma grade regularizada visou otimizar a manipulação e análise das informações, permitindo uma representação mais clara e aprofundada dos padrões espaciais que prevalecem na RESEX.




Figura 24 – Grade interna 1 x 1 km da Resex.
Fonte: Própria (2023)

3.2.3 Construção da RNA

A construção da Rede Neural Artificial foi realizada utilizando o software R Studio 4.2.3 em conjunto com o pacote "keras" e o framework "TensorFlow", visando a implementação de um modelo do tipo MLP com algoritmo de backpropagation.

O Keras é uma camada de abstração projetada para simplificar a construção e o treinamento de redes neurais, ao fornecer uma interface de alto nível que permite utilizar diferentes frameworks como backend para realizar as operações computacionais necessárias. Essa abordagem permite que os desenvolvedores se concentrem na lógica e na estrutura da rede neural, sem precisar lidar diretamente

com a complexidade dos frameworks subjacentes. O Keras oferece ainda uma experiência mais intuitiva e produtiva, aproveitando as capacidades e otimização dos diversos frameworks disponíveis (PRAKASH; KANAGACHIDAMBARESAN, 2021). Já o TensorFlow, é um framework de código aberto desenvolvido pela Google, é amplamente utilizado para computação numérica e machine learning. Ele fornece uma biblioteca abrangente para construção de modelos de aprendizado de máquina e deep learning. O TensorFlow é altamente flexível e escalável, permitindo treinar e implantar modelos em diferentes plataformas, desde dispositivos móveis até clusters de servidores (PRAKASH; KANAGACHIDAMBARESAN, 2021).

A combinação do Keras e TensorFlow proporcionou a criação de uma RNA robusta e eficiente para a análise dos dados, permitindo a exploração de recursos avançados de aprendizado de máquina e deep learning, além de oferecer uma interface simplificada para o desenvolvimento de modelos poderosos e escaláveis.

O modelo construído consistiu em uma estrutura de camadas, incluindo uma camada de entrada, uma camada oculta e uma camada de saída. Cada camada é implementada como uma camada densa, em que todos os neurônios estão conectados aos neurônios da camada anterior. Para realizar o treinamento da rede neural através do método de backpropagation, foi empregado o algoritmo de otimização RMSProp, o qual permitiu ajustar os pesos da rede de forma iterativa, visando minimizar o erro médio quadrático entre as saídas classificadas e os rótulos verdadeiros.

Para determinar a configuração mais adequada das camadas ocultas para a RNA, empregou-se uma abordagem de tentativa e erro. Foi utilizada a verificação do índice Kappa, e o intervalo de 1 a 20 neurônios artificiais nas camadas ocultas, para a validação da escolha da melhor arquitetura de rede para a classificação final.

O índice Kappa mede a concordância entre as previsões do modelo e os valores reais, levando em consideração a concordância esperada ao acaso (ROSENFELD e FITZPATRICK, 1986). No estudo utilizou o pacote "irr" para o cálculo do Índice Kappa no software Rstudio.

Para a construção e treinamento do modelo, o conjunto de dados foi dividido em duas partes, na proporção de 70% para treinamento e 30% para verificação (MITCHELL, 1997).

Observou-se um desequilíbrio entre o número de instâncias pertencentes à categoria "sem ocorrência de fogo" e o volume de dados relacionados à presença de fogo. Para mitigar essa disparidade, recorreu-se à aplicação de uma estratégia de balanceamento de classes.

O balanceamento de classes desempenha um papel crucial quando enfrentamos um desequilíbrio considerável entre as diferentes categorias em um problema de classificação, ou seja, quando uma das classes apresenta um número muito superior de exemplos em relação à outra. Nesse contexto, o modelo de aprendizado de RNA tende a viés em favor da classe majoritária, resultando em um desempenho inferior na classificação da classe minoritária (KOTSIANTIS et al. 2006).

Para abordar essa questão, optou-se pela técnica de super amostragem, na qual o número de instâncias da classe minoritária é aumentado durante a fase de treinamento da rede neural (TANTITHAMTHAVORN et al. 2018). Para implementar a super amostragem, utilizou-se o pacote "ROSE" no RStudio.

Após a seleção dos resultados obtidos nos intervalos de neurônios na camada oculta, realizada mediante a filtragem pela métrica do índice Kappa, a avaliação prosseguiu com a análise da precisão das redes neurais. Nesse estágio, foram empregados indicadores de desempenho essenciais, a saber: verdadeiro positivo, verdadeiro negativo, falso positivo e falso negativo.

- O verdadeiro positivo (VP) é uma métrica que representa a quantidade de exemplos positivos corretamente classificados pela rede neural (Jain et al., 2000). Isto é, corresponde ao número de casos em que a rede previu corretamente a presença de uma determinada classe. Na RNA construída, tal métrica representa as células em que há a presença de focos de calor e a RNA alcançou o mesmo resultado.
- O verdadeiro negativo (VN) é a métrica que representa a quantidade de exemplos negativos corretamente classificados pela rede neural (Jain et al., 2000). Refere-se ao número de casos em que a rede previu corretamente a ausência de uma determinada classe. Na RNA construída, esta métrica representa as células em que não há a presença de focos de calor e a RNA chegou ao mesmo resultado.

- O falso positivo (FP) é a métrica que representa a quantidade de exemplos negativos erroneamente classificados como positivos pela rede neural (Jain et al., 2000). Corresponde ao número de casos em que a rede previu incorretamente a presença de uma determinada classe. Na RNA construída, esta métrica representa as células em que não há a presença de focos de calor, mas a RNA indicou erroneamente que há.
- O falso negativo (FN) é a métrica que representa a quantidade de exemplos positivos erroneamente classificados como negativos pela rede neural (Jain et al., 2000). Significa o número de casos em que a rede previu incorretamente a ausência de uma determinada classe. Na RNA construída, esta métrica representa as células em que há a presença de focos de calor, mas a RNA indicou erroneamente que não há.

A incorporação desses indicadores métricos desempenha um papel fundamental na avaliação da precisão de redes neurais em tarefas de classificação (HASTIE et al., 2009). A partir dos resultados obtidos, esses indicadores são empregados para o cálculo de métricas essenciais, com o propósito de analisar e compreender o desempenho e a capacidade do modelo construído. As seguintes métricas foram examinadas no modelo desenvolvido:

Acurácia: Indica a taxa de acertos do modelo em relação ao total de amostras avaliadas (LANGE, 1995).

$$\frac{VP + VN}{VP + VN + FP + FN} \quad (26)$$

Predição Valores Verdadeiros: Proporção de casos classificados corretamente como negativos em relação ao total de casos classificados (LANGE, 1995).

$$\frac{VN}{VN + FN} \quad (27)$$

Predição Valores Verdadeiros (PVV): Representa a proporção de casos classificados corretamente como positivos em relação ao total de casos classificados (SCHMIDHUBER, 2015).

$$\frac{VP}{VP + FP} \quad (28)$$

Sensibilidade: Determina a proporção de casos positivos que foram corretamente identificados pelo modelo. (DUDA et al., 2012).

$$\frac{VP}{VP + FN} \quad (29)$$

Especificidade: Refere-se à capacidade desses modelos em determinar se os valores de entrada são bons ou ruins, ou seja, se estão dentro ou fora da faixa desejada (GHAFARI et al., 2021).

$$\frac{VN}{VN + FP} \quad (30)$$

F1- Score: é a média harmônica entre o recall e a precisão e fornece uma medida conservativa entre os erros tipos I e II, de modo que tanto falsos positivos quanto falsos negativos façam com que o valor dessa medida diminua (YAOHAO e MATION, 2018).

$$\frac{2 * (\text{Predição Valores Verdadeiros} * \text{Sensibilidade})}{\text{Predição Valores Verdadeiros} + \text{Sensibilidade}} \quad (31)$$

Área sob a curva (AUC): Avalia a capacidade discriminativa do modelo. e fornece uma medida geral da performance do modelo na distinção entre classes positivas e negativas (AHMED et al., 2020).

Por fim, foi produzido um mapa de verificação que compara os focos de calor classificados pela RNA com os focos de calor identificados no ano de 2020. Essa representação visual permitiu uma avaliação visual da capacidade da rede construída em relação à detecção de focos de calor.

3.3 RESULTADOS E DISCUSSÕES

As RNAs desenvolvidas passaram por um processo de validação, no qual o desempenho foi avaliado utilizando o índice Kappa. Essa avaliação foi fundamental para a seleção da arquitetura mais adequada à classificação de cada composição. Os resultados dessa análise estão apresentados na Figura 24.

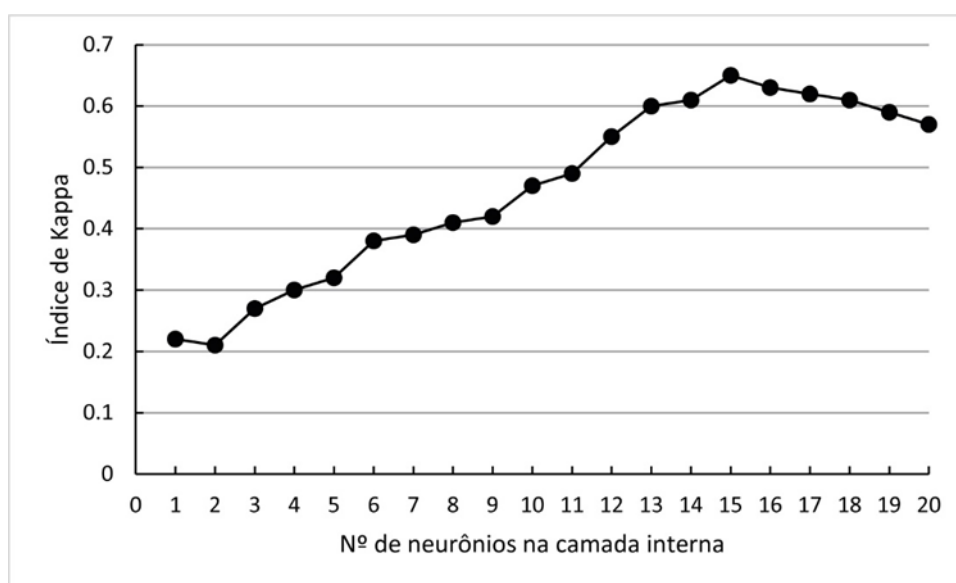


Figura 25 - Resultados do Índice de Kappa para avaliação dos modelos
Fonte: Própria (2023)

Para avaliar o desempenho do modelo, foram utilizadas métricas apropriadas, cujos resultados são apresentados na Tabela X. Essas métricas fornecem informações sobre a eficácia do modelo na classificação dos focos de calor.

Tabela 2 – Verificação da RNA construída.

Nº de neurônios	13	14	15	16	17	18	19
Acurácia	0.64	0.71	0.75	0.71	0.66	0.65	0.62
Valor Preditivo Negativo	0.61	0.70	0.70	0.72	0.69	0.67	0.65
Valor Preditivo Positivo	0.67	0.72	0.80	0.69	0.63	0.62	0.59
Sensibilidade	0.63	0.71	0.73	0.71	0.67	0.65	0.63
Especificidade	0.65	0.71	0.78	0.70	0.65	0.64	0.61
F1- Score	0.65	0.71	0.76	0.70	0.65	0.64	0.61
Área sob a Curva ROC	0.62	0.70	0.74	0.69	0.65	0.64	0.60

Fonte: Própria (2023)

Ao comparar os diversos modelos avaliados, a RNA) com 15 neurônios na camada oculta (Figura 25) sobressaiu-se ao apresentar resultados superiores em relação aos demais modelos desenvolvidos.




Figura 26 - Modelo da RNA construído.

Fonte: Própria (2023)

A análise de acurácia revelou que o modelo foi capaz de classificar corretamente 0.75 das células da grade da Resex, considerando o total de amostras avaliadas que foram 10.545 células. Essa taxa de acerto demonstra um desempenho superior em relação a uma classificação aleatória ou casual. Portanto, os resultados indicam que o modelo possui uma taxa satisfatória de precisão na sua capacidade de identificação.

A sensibilidade atingiu um valor aproximado de 0.73. Além disso, a especificidade, obteve um resultado de cerca de 0.78. Esses valores indicam que o modelo apresenta uma capacidade na ordem de 70% de identificar corretamente tanto os casos positivos quanto os negativos. O que é confirmado através dos valores de PVV de aproximadamente 0.80 e PVN de 0.70. Esses resultados evidenciam uma capacidade moderada do modelo em realizar previsões precisas tanto para casos positivos quanto negativos.

O AUC tem um valor próximo de 0.73, sugerindo, portanto, que o modelo possui uma boa capacidade de distinguir entre as classes positivas e negativas, no caso deste estudo, a distinção entre células da grade com foco e sem foco. Assim, com base nas métricas analisadas, os resultados obtidos evidenciam um desempenho considerável do modelo na tarefa de previsão de focos de calor. No entanto, também se observa a possibilidade de aprimorar sua capacidade de previsão por meio de refinamentos.

Após análise das métricas foi gerado um mapa de distribuição dos focos de calor na RECM a partir dos dados de entrada no modelo de modo a facilitar a visualização dos resultados obtidos. A Figura 26, ilustra a comparação entre os focos de calor observados na RECM para o ano de 2020 levando em consideração os valores previstos pelo modelo de RNA. Foi possível observar que, embora o modelo tenha previsto em torno de 70% de precisão a concentração de focos, algumas lacunas ou áreas permaneceram sem informação, porém foi possível identificar alguns padrões de localização dos focos. Isso indica que o modelo possui potencial para ser aprimorado, a fim de preencher as lacunas de células com focos não identificados.

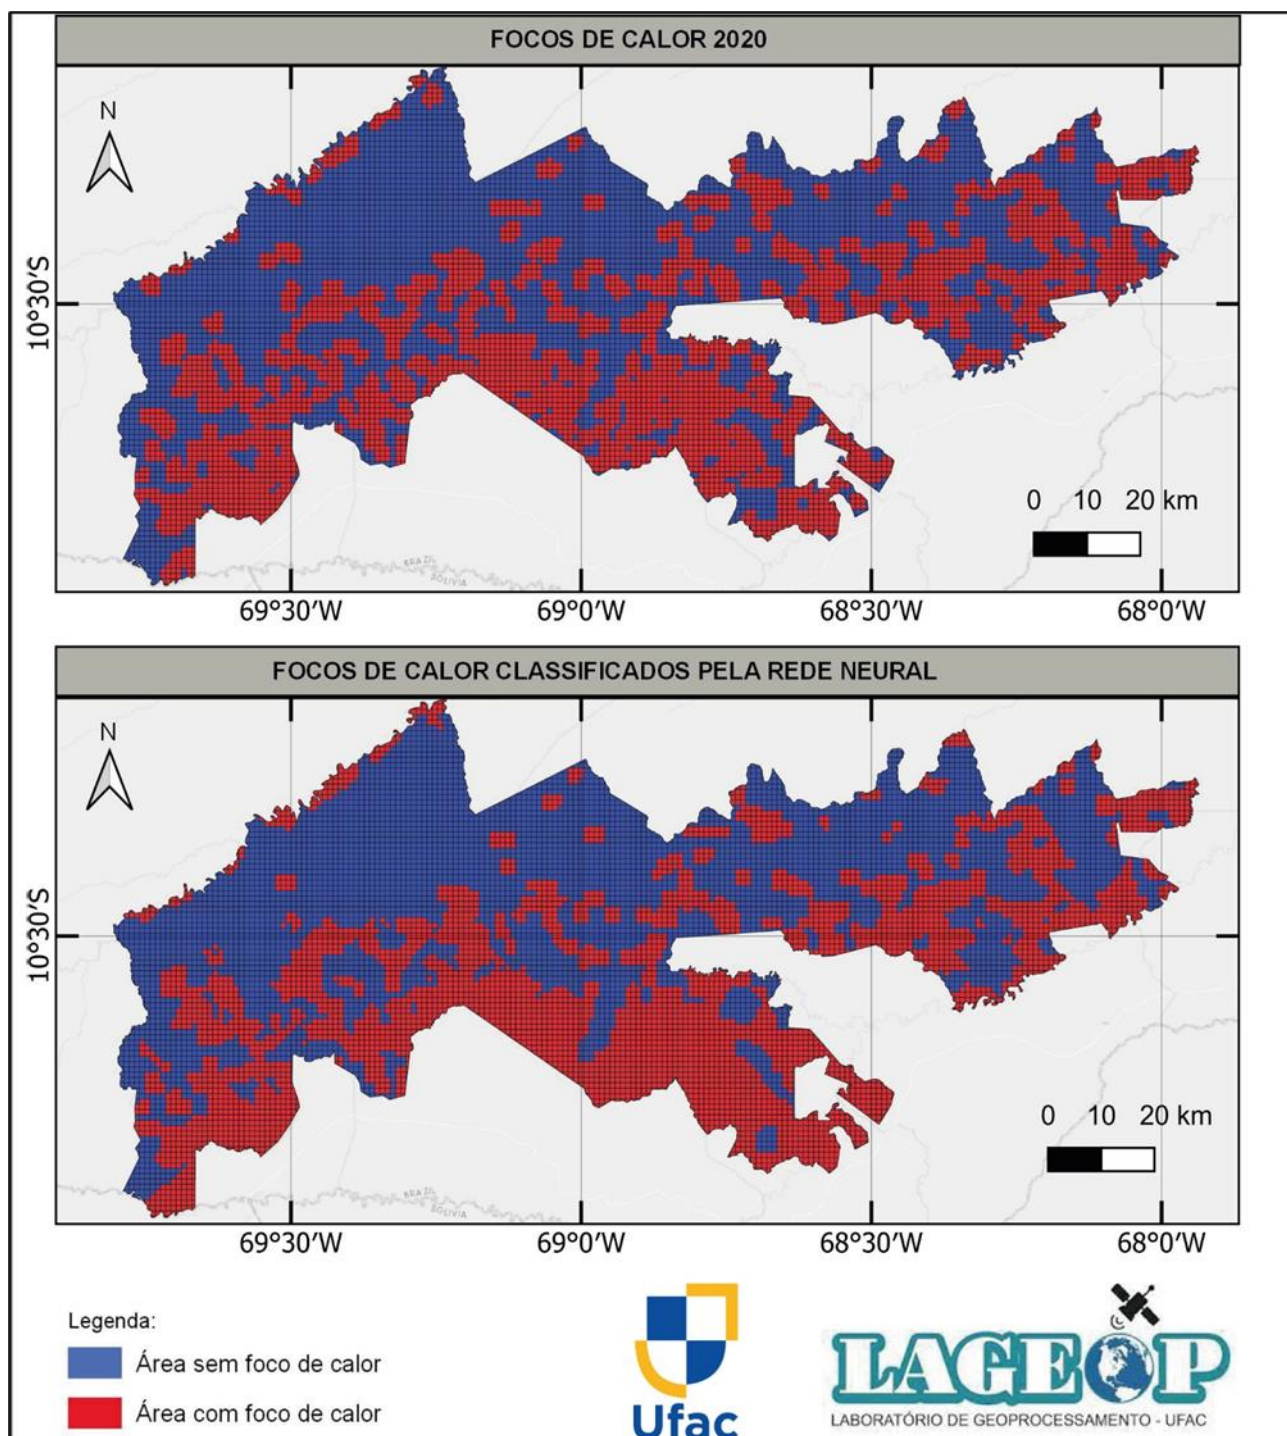


Figura 27 - Comparação entre os focos de calor observados na Resex em 2020 e os valores previstos pelo modelo de RNA.
Fonte: Própria (2023)

Do exposto, podemos dizer que o modelo apresenta uma correspondência satisfatória com os dados reais, embora algumas discrepâncias sejam evidentes. Essas discrepâncias podem ser atribuídas a vários fatores, como a complexidade do fenômeno em estudo, a disponibilidade e qualidade dos dados utilizados no treinamento e a própria natureza estocástica dos focos de calor.

Melhorias podem ser exploradas em diferentes aspectos do modelo, como por exemplo o ajuste de parâmetros, a inclusão de novos dados ou a utilização de algoritmos de aprendizado mais avançados. Ao buscar otimizar o desempenho do modelo, é possível alcançar resultados ainda mais precisos e confiáveis na previsão de focos de calor. Portanto, é recomendado realizar análises adicionais, investigar os pontos fracos identificados e aplicar estratégias de aprimoramento para elevar a capacidade preditiva do modelo a um nível ainda mais elevado. Essa abordagem permitirá maximizar a utilidade e a eficácia do modelo na identificação e prevenção de focos de calor.

Além disso, estratégias de otimização do modelo, como a seleção de diferentes arquiteturas de rede, o ajuste de hiperparâmetros e a aplicação de técnicas avançadas de aprendizado de máquina, podem ser utilizadas para melhorar a capacidade preditiva e o desempenho geral do modelo.

Embora haja espaço para aprimoramentos, os resultados obtidos até o momento indicam que o modelo de RNA possui uma base sólida e demonstra potencial para auxiliar no monitoramento de focos de calor em áreas de proteção ambiental. O contínuo desenvolvimento e refinamento desse modelo podem contribuir significativamente para a proteção e preservação de áreas naturais ameaçadas por fogos.

3.4 CONCLUSÃO

A aplicação de um modelo de Rede Neural Artificial na previsão de focos de calor dentro da Reserva Extrativista Chico Mendes revelou resultados promissores no que se refere à identificação das áreas propícias à ocorrência de focos. Contudo, há margem para aprimorar sua precisão mediante a incorporação de novas técnicas e abordagens.

Os resultados obtidos evidenciam a capacidade da Rede Neural Artificial em capturar padrões e identificar, de forma aproximada, a localização dos focos de calor. Isso indica o potencial do modelo, o qual pode ser otimizado por meio da implementação de técnicas complementares para preencher lacunas e fortalecer sua capacidade preditiva em áreas específicas.

Em relação a áreas de conservação ambiental com foco na vida extrativista, seria benéfico considerar a inclusão de variáveis que transcendam o escopo tradicional de dados climáticos. Por exemplo, a concentração de seringais dentro da Resex e as variações econômicas dos produtos provenientes das atividades extrativistas. Além disso, é recomendado investigar a aplicabilidade do modelo em outras regiões e períodos, com o intuito de avaliar sua capacidade de generalização e adaptabilidade a contextos diversos. Isso permitirá uma compreensão mais abrangente dos padrões de ocorrência de focos de calor em diferentes áreas protegidas, bem como a identificação de fatores específicos que influenciam a previsão nesses contextos.

É fundamental salientar que a previsão de focos de calor é um desafio complexo, envolvendo uma interação complexa de fatores diversos. Assim, o contínuo aprimoramento do modelo de Rede Neural Artificial deve ser acompanhado pela coleta e disponibilização de dados mais abrangentes e atualizados, assim como por estudos complementares que contribuam para um melhor entendimento do fenômeno do fogo na Resex.

Em síntese, os resultados obtidos até o momento indicam que a aplicação de um modelo de Rede Neural Artificial para classificação de focos de calor na Reserva Extrativista Chico Mendes possui um potencial promissor. Mediante a adoção de novas técnicas, estratégias de otimização e o constante aprimoramento do modelo, será possível alcançar uma maior precisão na identificação das áreas com maior risco de fogo, promovendo assim a preservação e a gestão sustentável dessas áreas naturais preciosas.

CONSIDERAÇÕES FINAIS

O Banco de Dados de Queimadas do Instituto Nacional de Pesquisas Espaciais (INPE) desempenhou um papel fundamental nos estudos conduzidos, fornecendo

informações essenciais. Através desse banco de dados, tornou-se possível realizar análises temporais e espaciais das ocorrências de fogo na Reserva Extrativista Chico Mendes. Adicionalmente, foi viável desenvolver uma Rede Neural Artificial capaz de classificar a localização dos focos de calor nas áreas da Reserva.

Apesar do papel crucial que as reservas extrativistas desempenham na preservação ambiental e cultural, elas não estão isentas das pressões decorrentes da exploração predatória. Portanto, a criação e disseminação de estratégias de monitoramento se tornam fundamentais para assegurar que as áreas protegidas continuem a desempenhar sua função de mitigar o desmatamento. Isso deve incluir a implementação de medidas de proteção ambiental em conjunto com outras políticas direcionadas ao meio ambiente. É crucial vincular o fortalecimento das áreas protegidas e à valorização das comunidades extrativistas.

Os avanços significativos na área de inteligência artificial têm proporcionado um progresso notável em várias áreas, incluindo o monitoramento cada vez mais aprimorado e preciso de queimadas e incêndios florestais. No entanto, fica evidente que o desafio central para a redução das ocorrências de fogo em ambientes de conservação depende do comprometimento dos gestores em aproveitar integralmente essas avançadas ferramentas tecnológicas disponíveis, a fim de fortalecer as estratégias de contenção das incidências de fogo.

REFERÊNCIAS

ACRE. Governo do Estado. **Diagnóstico socioeconômico e cadastro da Reserva Extrativista Chico Mendes – Plano Resex Sustentável** – Documento Preliminar. Rio Branco: Sema, 2010.

AHMED, Abuzoor., USMAN, Mohammed., MAHMUD, Hasan. Detection and classification of ovarian cancer using deep convolutional neural networks. *Journal of Medical Imaging and Health Informatics*, v. 10, n. 6, p. 1321–1325, 2020.

ALENCAR, Antônio. **Além do conceitual: lições empíricas sobre o uso do fogo para o manejo da vegetação em áreas protegidas do Brasil**. Geografia Aplicada, 60, 241-249, 2015.

ALLEGRETTI, Mary. Reservas Extrativistas: uma proposta de desenvolvimento para a floresta Amazônica. **Fundação SEADE**, São Paulo, v. 3, n. 4, p. 23-29.1989.

ALMEIDA, Paulo Santos de., TIOSSO, Açucena, SILVA, Jéssica Sá Fernandes da. Análises e considerações sobre as influências do código florestal brasileiro na

política nacional sobre mudança do clima: lei nº 12.651/12 e suas alterações. **Revista de estudos ambientais**, v.15, n. 2, p. 16-24, 2013.

ALMEIDA. Mauro Barbosa de., ALLEGRETTI. Mary Helena., POSTIGO. Augusto. O legado de Chico Mendes: êxitos e entraves das Reservas Extrativistas. Edição especial: 30 Anos do Legado de Chico Mendes. **Desenvolvimento e meio ambiente**, Paraná, Vol. 48, 2018. Disponível em: < <https://revistas.ufpr.br/made/article/view/60499/36935>>.

ALVES, Havana Diogo., VALENÇA, Mêuser Jorge Silva. Seleção de fatores de risco de lesões em atletas, através da extração de conhecimento dos pesos de uma rede neural. **Fortaleza: 10th Brazilian Congress on Computational Intelligence**, 2011.

ANA. **Agência Nacional de Águas**. 2022. Disponível em: < <https://www.snirh.gov.br/hidroweb/apresentacao>>. Acesso: 24 de jan. de 2022.

ARAGÃO, Luiz., ANDERSON, Liana., FONSECA, Marisa., ROSAN, Thais., VEDOVATO, Laura., WAGNER, Fabien., SILVA, Camila., JUNIOR, Celso Silva., ARAI, Egidio., AGUIAR, Ana., BARLOW, Jos., BERENGUER, Erika., DEETER, Merritt., DOMINGUES, Lucas., GATTI, Luciana., GLOOR, Manuel., MALHI, Yadvinder., MARENGO, Jose., MILLER, John., PHILLIPS, Oliver., SAATCHI, Sassan. 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature Communications**. 2018. DOI: <https://doi.org/10.1038/s41467-017-02771-y>.

ARAÚJO, Elis., BARRETO, Paulo., MARTINS, Heron. Áreas protegidas críticas na Amazônia no período de 2012 a 2014. **IMAZON 25 anos**, Belém, p. 20. 2015.

ASSUNÇÃO, João. Combinando dados de satélite com realidades locais: desafios de aumentar as medições participativas da biomassa florestal. **Mudança Ambiental Global**, 47, 20-31, 2017.

BADARUDDIN, Vellani., SETIAWAN, Muhammad. B., SUTIKNO, Sarwono. Estimation of rice crop planting area and phenological analysis using MODIS NDVI in Banyuwangi, East Java, Indonesia. **Journal of Environmental Management and Tourism**, 10(2), 308-315. 2019.

BARBER, Christopher., COCHRANE, Mark., SOUZA, Carlos., LAURANCE, Willian. Roads, deforestation, and the mitigating effect of protected areas in the Amazon. **Biological Conservation**, 2014.

BARBOSA, Alencar. Detecção e Mapeamento de Focos de Calor em Florestas com o Uso de Imagens Orbitais. **Revista de Geografia Norte Grande**, p. 77-91. 2017.

BARBOSA, Diego. **Agricultura familiar e pecuária no Acre: discussões a partir do PAD Pedro Peixoto**. Rio Branco: UFAC, 2017.

BARLOW, Josias. **A importância crítica de considerar o fogo em programas de REDD+**. *Conservação Biológica*, 154, 1-8. 2012.

BATISTA, Antônio Carlos. Detecção de incêndios florestais por satélites. **Revista FLORESTA**, Rio Negro, v.34, n.2, 2004. Disponível em: <<https://revistas.ufpr.br/floresta/article/view/2402/2010>>. Acesso em: 02 de jul. de 2022.

BERNOUX, Martial., CARVALHO, Maria. VOLKOFF, Boris., CERRI, Carlos Clemente. CO₂ emission from mineral soils following land-cover change in Brazil. **Global Chang**, Biol., 7:779-787, 2001.

ZHENG, Bo., PHILIPPE, Ciais., FREDERIC, Chevallier., EMILIO, Chuvieco., YANG, Chen., HUI, Yang. Increasing forest fire emissions despite the decline in global burned area. **Science advances**, 2021. Disponível em: <<https://www.science.org/doi/full/10.1126/sciadv.abh2646>>. Acesso em: 30 de ago. de 2023.

BRASIL. **Áreas Protegidas**. ICMBio, 2023. Disponível em: <<https://www.icmbio.gov.br/portal/unidades-de-conservacao/banostop>>. Acesso em: 01 de set. de 2022.

BRASIL. **Brasil em Relevô**. Embrapa monitoramento por satélite, 2022.

BRASIL. **Instituto Chico Mendes de Conservação da Biodiversidade**. Atlas das Unidades de Conservação do Brasil. 4ª Edição. 2008.

BRASIL. **LEI Nº 9.985, DE 18 DE JULHO DE 2000**. Brasília, 2000.

BRASIL. Ministério de Ciência e Tecnologia. **Inventário brasileiro das emissões e remoções antrópicas de gases de efeito estufa**. Brasília, 2009. 19p.

BRASIL. **Plano de Utilização da Reserva Extrativista Chico Mendes** – Portaria n.º 60, de 28 de agosto de 2008, Brasília: ICMBio, 2008.

BROWN, Foster., SCHROEDER, Wilfrid., SETZER, AlbertoA., MALDONADO, Monica De Los Rios., PANTOJA, Nara., DUARTE, Alejandro., MARENGO, Jose.,. Monitoring fires in southwestern Amazonia rain forests. **EOS, American Geophysical Union**. p. 253, 264. 2006.

CASTRO, Caio., RIBEIRO, Andreia. **Análise espacial do potencial impacto de mudanças climáticas sobre áreas urbanas por meio de técnicas de geoprocessamento, sensoriamento remoto e modelagem hidrológica**. Revista Brasileira de Geografia Física, 11(06), 2404-2426. 2018.

CEMADEN. **Centro Nacional de Monitoramento e Alertas de Desastres Naturais**. 2022. Disponível em: < <https://www.gov.br/cemaden/pt-br>>. Acesso em 13 de fev. de 2022.

CHUVIECO, Emilio., ALLGOWER, Britta., SALAS, Javier. Integration of Physical and Human Factors in Fire Danger Assessment. **World Scientific Publishing, Singapore**, 4. ed p. 197–218. 2003

COPERTINO, Margareth., PIEDADE, Maria Teresa Fernandez., VIEIRA, Ima Célia Guimarães., BUSTAMANTE, Mercedes. Desmatamento, fogo e clima estão intimamente conectados na Amazônia. **Cienc. Cult**, 2019. Disponível em<<http://dx.doi.org/10.21800/2317-66602019000400002>>. Acesso em: 01 de nov. de 2022.

COSTA, Pedro Luiz. **Estatística**. São Paulo: Edgard Blücher. p.266, 2002.

COSTA, V. M. **Métodos de detecção de focos de calor utilizando imagens de sensoriamento remoto**. 2019.

DE MORAES, Paulo Cerri., ADAM, Cristina. Extrativismo Sustentável e Unidades de Conservação. **NR, Série Desenvolvimento Sustentável**, n. 57. 2002.

DOR, Moraes. Incêndios no Sistema Terrestre: Entendendo as Interações com o Clima, a Qualidade do Ar e a Dimensão Humana. **Eos**, p.99. 2018.

DRUCK, Suzana., CARVALHO, Marília Sá., CÂMARA, Gilberto., MONTEIRO, Antônio Miguel. Análise Espacial de Dados Geográficos. **EMBRAPA**, Brasília, 2004.

DUDA, Richard., HART, Peter., STORK, David. **Pattern Classification**. Second edition, 2012.

EMBRAPA. **Brasil em relevo**. 2022. Disponível em: <<https://www.cnpm.embrapa.br/projetos/relevobr/>>. Acesso em: 24 de fev. de 2022.

EPHRAUMS, John. Manual of Remote Sensing 2: Remote Sensing for Resources Development and Environmental Management. American Society of Photogrammetry, 1997.

ESCADA, Marcos., Carvalho, Santos. Sensoriamento remoto: princípios e aplicações. **Editora UNESP**, 1996.

FEARNSIDE, Philip. Deforestation in Brazilian Amazonia: History, rates and consequences. **Conservation Biology**, Vol. 19, n.3, p. 680-688, 2005.

FERNÁNDEZ, Jesús Martínez., VEGA-GARCIA, Cristina., CHUVIECO, Emilio. Human-caused wildfire risk rating for prevention planning in Spain. **Journal of Environmental Management**, v. 90, n. 2, p. 1241–1252, 2009.

FERREIRA, Luiz. Reserva Extrativista do Alto Juruá: uma análise da gestão compartilhada pela população extrativista. In: **Anais do Congresso Brasileiro de Gestão Ambiental e Sustentabilidade**, Vol. 7, n. 1, p. 598, 2018.

FILHO, D. B.; ROCHA, E. C.; SILVA, J., PARANHOS, R, NEVES, J. A., SILVA, M. B. **Desvendando os Mistérios do Coeficiente de Correlação de Pearson: o Retorno**. Leviathan, N. 8, pp.66-95, 2014.

FONTES, Cristiane., LEITE, Marcelo. Reserva Extrativista Chico Mendes é atacada sem reação do poder público. **Folha de São Paulo**, 2022. Disponível em: <<https://www1.folha.uol.com.br/ambiente/2022/09/reserva-extrativista-chico-mendes->

e-atacada-sem-reacao-do-poder-publico-diz-angela-mendes.shtml>. Acesso em: 02 de set. de 2022.

FRANCO, Elis. Extremos meteorológicos podem se tornar “novo normal”, diz meteorologista. **CNN BRASIL**, 2021. Disponível em:<<https://www.cnnbrasil.com.br/nacional/extremos-meteorologicos-podem-se-tornar-novo-normal-diz-meteorologista/>>. Acesso em: 16 set. 2022.

FREITAS, Josimar da Silva., SILVA, David Costa., RODRIGUES, Marcos. Áreas protegidas en el Amazon: un análisis institucional extractiva reserva el Alto Juruá. **Contribuciones a Las Ciencias Sociales**, Málaga, 2016.

FREITAS, Marcos. **A criação das reservas extrativistas na região amazônica: uma proposta de investigação do órgão gestor e do manejo florestal comunitário**. In: XVIII Encontro Nacional de Estudos Populacionais, 2012.

GARRIDO, Bibiana. Desmatamento na Amazônia cresceu 56,6% sob governo Bolsonaro. **IPAM**. Belém, 2022. Disponível em: < <https://ipam.org.br/desmatamento-na-amazonia-cresceu-566-sob-governo-bolsonaro/>>. Acesso em: 28 de ago. de 2022.

GHAFFARI, Mohsen. A Novel ROI-Based Deep Learning Framework for Unsupervised Cardiac Abnormality Detection from Multimodal Images. **IEEE Internet of Things Journal**, p. 11, 2021.

GRANCHI, Giulia. Ciclone extratropical: o que é o fenômeno que causa chuvas e ventania em parte do Brasil. **BBC NEWS**, 2022. Disponível em:<<https://www.bbc.com/portuguese/brasil-62498923>>. Acesso em: set. 2022.

HASTIE, Trevor., TIBSHIRANI, Robert., FRIEDMAN, Jerome. **The elements of statistical learning: data mining, inference, and prediction**. Springer Science & Business Media, 2009.

HAYKIN, Sünon. **Redes Neurais: Princípios e prática**. 2a. ed. Porto Alegre: Bookman, 2001.

ICMBIO. **Reserva Extrativista do Alto Juruá**. 2021. Disponível em: "<https://www.icmbio.gov.br/portal/unidades-de-conservacao/banostop>". Acesso em: 14 de ago. de 2022.

IMAZON. **Boletim de desmatamento da Amazônia legal (outubro de 2014)**. Imazon, 2014. Disponível em: <<https://imazon.org.br/boletim-do-desmatamento-da-amazonia-legal-outubro-de-2014/>>. Acesso em: 14 de jun. de 2023.

IMAZON. **Boletim de desmatamento da Amazônia legal**, 2015. Disponível em:<<https://imazon.org.br/boletim-do-desmatamento-da-amazonia-legal-julho-de-2015-sad/>>. Acesso em: 30 de out. de 2022.

IMAZON. **Símbolo da luta pela floresta, Resex Chico Mendes é a área protegida mais pressionada pelo desmatamento na Amazônia**.2022. Disponível em: <<https://imazon.org.br/imprensa/simbolo-da-luta-pela-floresta-resex-chico->

mendes-e-a-area-protegida-mais-pressionada-pelo-desmatamento-na-amazonia/>. Acesso em 06 de fev. de 2023.

INEP. **Queimadas**. Brasília, 2021. Disponível em: < https://queimadas.dgi.inpe.br/queimadas/portal-static/estatisticas_estados/>. Acesso em: 23 de jul. de 2022.

IPAM. **Amazônia em Chamas**. 2018. Disponível em: < https://ipam.org.br/wp-content/uploads/2018/07/Amaz%C3%B4nia-em-Chamas_2018-1.pdf. > Acesso em: 01 de fev. de 2022.

IPAM. **Amazônia e Pampa lideram queimadas de janeiro a julho de 2022**. 2022. Disponível em: <<https://ipam.org.br/amazonia-e-pampa-lideram-queimadas-de-janeiro-a-julho-de-2022/>>. Acesso em: set. 2022.

IPPC. **Climate Change 2022: Impacts, Adaptation and Vulnerability**. 2022. Disponível em: <<https://www.ipcc.ch/meeting-doc/ipcc-wgii-12-and-ipcc-55/>>. Acesso em: set. de 2022.

JAEGER, Herbert., HAAS, Harald. **Harnessing Nonlinearity: Predicting Chaotic Systems and Saving Energy in Wireless Communication**. Reports, 2004.

JANSEN, Alencar., NUNES, Paulo., SILVA, Vivian., CÉSAR. Extrativismo vegetal e conservação do ambiente: a experiência da Reserva Extrativista Tapajós Arapiuns, no município de Aveiro, Oeste do Pará. **Revista Multiscientia**, v. 2, n. 1, p. 209-221, 2011.

JENSEN, John. **Remote Sensing of the Environment: An Earth Resource Perspective**. Pearson Education. 2016.

BISHOP, Christopher. **Neural Networks for Pattern Recognition**. Oxford University Press, 1996.

LIMA, Alvaro., LACERDA, Wilian, NETO, Heitor. Seleção de características de dados utilizando Redes Neurais Artificiais. **Lavras: XIII Brazilian Symposium on Information Systems**, 2017.

LIU, Yanhui., HUANG, Junbao., XIAO, Ruihua., MA, Shiwei., ZHOU, Pinggen. Research on a Regional Landslide Early-Warning Model Based on Machine Learning—A Case Study of Fujian Province, China. **Forests**, 2022. Disponível em: < <https://www.mdpi.com/1999-4907/13/12/2182>>. Acesso em: 12 de fev. de 2023.

LONGLEY, Paul., GOODCHILD, Michael., MAGUIRE, David., RHIND, DAVIDD. **Geographic information systems and science**. **Chichester: John Wiley and Sons**. P.517, 2005.

LOPES, Dercilio Junior., BOBADILHA, Gabrielly., BEDETTE, Amanda Peres. **Analysis of Lumber Prices Time Series Using Long Short-Term Memory Artificial Neural Networks**. **Forests** 2021. Disponível em: < <https://www.mdpi.com/1999-4907/12/4/428>>. Acesso em: 31 de dez. de 2023.

LUZADO, Antonio José., FILHO, Rafael March., RUBIM, Igor Brum. Análise espacial exploratória com o emprego do índice de Moran. **GEOgraphia**, 2017.

MACIEL, Raimundo., MANGABEIRA, João., KASSAI, José Roberto. Avaliação econômica da pecuária de gado bovino na reserva extrativista (resex) chico mendes. **Editora Omnis Scientia**, Reserva extrativista “chico mendes” a sociedade 25 anos depois. Triunfo, 2021. Disponível em: <<https://editoraomnisscientia.com.br/catalogos/ciencias-agrarias/reserva-extrativista-chico-mendes-a-sociedade-25-anos-depois/>>. Acesso em: 30 de mai. de 2023.

MARÇAL, Alencar., FERNANDES, Raian., BEZZON, Gustavo. Monitoramento da preservação de fragmentos de mata atlântica utilizando sensoriamento remoto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, p.553-559, 2012.

MARGULIS, Sergio. Quem são os agentes do desmatamento na Amazônia e por que eles desmatam? **UFRRJ**, Brasília, 2001.

MASCARENHAS, Flávio de Sousa., BROWN, Irving Foster., SILVA, Sonaira Souza da. Desmatamento e incêndios florestais transformando a realidade da Reserva Extrativista Chico Mendes. **Desenvolvimento e Meio ambiente**. Edição especial: 30 Anos do Legado de Chico Mendes Vol. 48, Paraná, 2018. Disponível em: <<https://revistas.ufpr.br/made/article/view/58826>>. Acesso em: 17 de abr. de 2022.

MMA. **Unidades de Conservação do Brasil: patrimônio do povo brasileiro esperança de um futuro para a humanidade**. Brasília, 2007

MOLION, Luiz. Aquecimento global, El Niños, Manchas Solares, Vulcões e Oscilação Decadal do Pacífico. **Clima Análise**, CPTEC/INPE, 2005.

MONITCHELE, Marília. Em 2022, Brasil queimou o equivalente ao estado do Acre. **VEJA**, 2023. Disponível em: <<https://veja.abril.com.br/ciencia/em-2022-brasil-queimou-o-equivalente-ao-estado-do-acre/>>. Acesso em: 23 de set. de 2022

MORADI, Fardin., DARVISHSEFAT, Ali Asghar., POURRAHMATI, Manizheh Rajab., DELJOUEI, Azade., BORZ, Stelian Alexandru. Estimating Aboveground Biomass in Dense Hyrcanian Forests by the Use of Sentinel-2 Data. **Forests**, 2022. Disponível em:<<https://www.mdpi.com/1999-4907/13/1/104>>. Acesso em: 24 de mar. de 2023.

MORTON, Diego. Avaliação rápida do desmatamento anual na Amazônia brasileira usando dados MODIS. **Interações com a Terra**, p.1-22, 2005.

MUGHAZ, Dror., COHEN, Michael., MEJAHEZ, Sagit., ADES, Tal., BOUHNİK, Dan. From an artificial neural network to teaching. **Interdisciplinary Journal of e-Skills and Lifelong Learning**, 2020. Disponível em: <<http://www.ijello.org/Volume16/IJELLv16p001-017Mughaz6498.pdf>>. Acesso em: 19 de ago. de 2022.

MUÑOZ, Ezequiel., GURGEL, Fernando., VALERIANO, Dalton., SANTOS, Nunes. Discriminação de classes puras de cultura da cana-de-açúcar em

agrupamentos usando CNN aplicada ao sensoriamento remoto. **Boletim de Ciências Geodésicas**, p.41-60, 2018.

NASA. **Prediction of Worldwide Energy Resources**. Disponível em:<<https://power.larc.nasa.gov/data-access-viewer>>. 2022. Acesso em: 01 de set. 2022.

NUNES, Raimundo. FMA um novo índice de perigo de incêndios florestais para o estado do Paraná. **Brasil Floresta**, v. 36, n. 1, p. 75–91, 2006.

OLIVEIRA, Ulisses Costa de., OLIVEIRA, Petronio Silva de. Mapas de kernel como subsídio à gestão ambiental: análise dos focos de calor na Bacia Hidrográfica do Rio Acaraú, Ceará, nos anos 2010 a 2015. **Espaço Aberto**, v. 7, p.87-99, 2017.

PACHECO, Fernando., WITKOWSKI, Ricardo. Sensoriamento remoto e geoprocessamento na avaliação da mudança no uso da terra. **Revista Brasileira de Engenharia Agrícola e Ambiental**, p. 544-552, 2005.

PARK, Geonha., LEE, Yun-Gyo., YOON, Ye-Seul., AHN, Ji-Young., LEE, Jei-Wan., JANG, Young-PyY.-P. Machine Learning-Based Species Classification Methods Using DART-TOF-MS Data for Five Coniferous Wood Species. **Forests**, 2022. Disponível em: < <https://www.mdpi.com/1999-4907/13/10/1688>>. Acesso em: 06 de fev. de 2023.

PEDROSO, Nelson Novaes., MURRIETA, Rui Sérgio., ADAMS, Cristina. A agricultura de corte e queima: sistema em transformação. **Boletim Museu Paraense Emílio Goeldi**. Ciências Humanas, Belém, 2008.

PEIXOTO, Roberto. EUA, Europa e Ásia enfrentam secas recordes; qual a gravidade do cenário e as suas causas? **G1**, 2022. Disponível em: <<https://g1.globo.com/meio-ambiente/aquecimento-global/noticia/2022/08/29/eua-europa-e-asia-enfrentam-secas-recordes-qual-a-gravidade-do-cenario-e-as-suas-causas.ghtml>>. Acesso em: 25 de set. 2022.

PEREIRA, Rogerio., SOARES, João. Uso Remoto de técnicas de sensoriamento em análise da evolução da degradação das áreas úmidas do Amapá: aplicação de técnicas de sensoriamento remoto. **Boletim do Museu Paraense Emílio Goeldi**. Ciências Naturais, p. 79-90, 2018.

PESARESI, M., EHRLICH, D., SCHOWENGERDT, R., MERUCCI, L. **Remote Sensing Techniques for Dam Monitoring: Review and Some Perspectives**. Remote Sensing, 10(4), 541. 2018.

PIVELLO, Vania. O uso de golpes de fogo para evitar fugas durante queimadas prescritas e incêndios florestais. **Cartas de pesquisa ambiental**, v.14. 2019.

PONTES, Fernando. **Chico, a reserva e o boi. 2015**. Disponível em: <<http://politicanafloresta.blogspot.com.br/2015/11/chico-reserva-e-o-boi.html>>. Acesso em: 25 de fev de 2022.

PRAKASH, Kolla Bhanu., KANAGACHIDAMBARESAN. **Programming with TensorFlow: Solution for Edge Computing Applications**. Springer, 1st ed, 2021.

REGAN, Helen. Austrália sofre com incêndios florestais e onda recorde de calor. **CNN BRASIL**, 2020. Disponível em: <<https://www.cnnbrasil.com.br/internacional/australia-sofre-com-incendios-florestais-e-onda-recorde-de-calor/>>. Acesso em: set. 2022.

RIBEIRO, Helena., ASSUNÇÃO, João Vicente., **Efeitos das queimadas na saúde humana**. Scielo Brasil, 2002. Disponível em: <<https://www.scielo.br/j/ea/a/5KxLnYV6c8kRph4Dxd49rv/?lang=pt>>. Acesso em: 10 de dez. de 2021.

RIBEIRO, Sérgio., ALMEIDA, Oriana., ÁVILA, Saulo., OLIVEIRA, Wesley., **Pecuária e desmatamento: uma análise das principais causas diretas do desmatamento na Amazônia**. Scielo: Belo Horizonte, 2009. Disponível em: <<https://www.scielo.br/j/neco/a/jZHjd9B8ZghY7tG9G7qchTk/?lang=pt>>. Acesso em: 02 de nov de 2022.

ROCHA, Kaio., ARAUJO, Antônia., DUETI, Luiz. Focos de calor no sudoeste da Amazônia: indicador do efeito da Ação Civil Pública – ACP do “fogo zero. **Braz. J. of Develop**, v. 6, n.5, p.30597-30609, Curitiba, 2020.

SAMPAIO, Otávio Bezerra. O impacto de incêndios florestais nas unidades de conservação brasileiras. **Instituto ambiental do Paraná** . p.138 – 152, 2020. Disponível em: <http://www.iat.pr.gov.br/sites/agua-terra/arquivos_restritos/files/documento/2020-09/unidades_de_conservacao.pdf#page=133>. Acesso em: 28 de dez de 2022.

SANT’ANA, Raian, CARVALHO, Santos., JESUS, Araújo. Espacialização das ocorrências da companhia de polícia de proteção ambiental – COPPA, através do uso de geotecnologias. **Revista Eletrônica: tempo, técnica e território**, v. 5, p.62-71, 2014.

SANTOS, Gabriel Garreto dos., NERIS, João Paulo., SANTOS, Maciel Garreto dos., FREITAS, Tatiana Pará Monteiro de. Uso de geotecnologias na análise espacial dos focos de calor no município de São Félix do Xingu, Pará. **Publicações Avulsas**. Universidade Federal do Piauí, Teresina, 2020.

SCHMIDHUBER, Jürgen. Deep learning in neural networks: an overview. **Neural networks: the official journal of the International Neural Network Society**, v. 61, p. 85–117, 2015.

SCOLESO, Fabiana., SANTOS, Levi Manoel dos. As mudanças no Novo Código Florestal, seus impactos nas territorialidades e as novas dinâmicas acerca das fronteiras: mundialização do capital e neoextrativismo na Amazônia Legal. **XVII Encontro Regional de História da ANPU**, Paraná, 2020.

SETZER, Alan., MORELLI, Fernando. Diferenças na quantificação de focos de queima de vegetação conforme o satélite e o sensor do monitoramento. **5º. Simpósio**

Sul-Americano sobre Controle de Incêndios Florestais, Campinas. São Paulo, p.264-267, 2011.

SETZER, Alan. Queimadas em áreas de fronteiras agrícolas na Amazônia. **Acta Amazônica**, p. 935-940, 2020.

SILVA, Barbosa. Práticas Extrativistas em Unidades de Conservação: Estudos de Casos nas RESEX Marinha de Arraial do Cabo (RJ) e RESEX Marinha de Canavieiras (BA). **Sociedade e Desenvolvimento Rural**, v. 10, n. 2, pág. 5-32, 2017.

SILVA, Carlos. Fire in the Forests of the Past, Present and Future. **Ecosystem Science and Applications**, Cham. 2021.

SILVA, Larcerda. Mapeamento de ocorrências de incêndios ativos na floresta amazônica usando dados do satélite Sentinel-3. **Aplicações de Sensoriamento Remoto: Sociedade e Meio Ambiente**, 2020.

SILVA, Sonaira., COSTA, Jéssica., SOUZA, Francisco Salatiel., NASCIMENTO, Eric., SILVA, Ismael., PEREIRA, Moises., MELO, Antonio Willian. **Queimadas 2020 no Estado do Acre**. Cruzeiro do Sul: UFAC, 2020.

IMAZON. **Símbolo da luta pela floresta, Resex Chico Mendes é a área protegida mais pressionada pelo desmatamento na Amazônia**. IMAZON, 2022. Disponível em: <<https://imazon.org.br/imprensa/simbolo-da-luta-pela-floresta-resex-chico-mendes-e-a-area-protegida-mais-pressionada-pelo-desmatamento-na-amazonia/>>. Acesso em 06 de fev. de 2023.

SIVIERO, Amauri., TEIXEIRA, Paulo Eduardo Ferline., SANTOS, Rosana Cavalcante dos. A produção agropecuária nas Reservas Extrativistas do Acre. **Embrapa publicações**, p.337-378, 2019.

SOARES, Ronaldo Viana. Queimas controladas: prós e contras. **I Fórum Nacional sobre Incêndios Florestais**. III Reunião Conjunta IPEF-FUPEF-SIF, p. 6-10, 1995.

SOARES, Ronaldo Viana., BATISTA, Antonio Carlos. **Incêndios Florestais: controle, efeitos e uso do fogo**. Curitiba, UFPR, p.264, 2007.

SOUZA, Cassio. Incidência de fogo no Cerrado do estado de Goiás entre os anos de 2012 e 2015. **Revista Eletrônica Simplificando o Espaço**, p.209-236. 2016.

SOUZA., CASAVECCHIA., STANGERLIN. Avaliação dos riscos de ocorrência de incêndios florestais nas regiões Norte e Noroeste da Amazônia Matogrossense. **SCIENTIA PLENA**, Mato Grosso, v.8, n.5, 2012. Disponível em <<https://scientiaplena.org.br/sp/article/view/553/491>>. Acesso em: 23 de set. de 2022.

TAVARES, Lucas., Groenwald, Jonas. Sensoriamento remoto aplicado ao mapeamento da cobertura florestal da bacia do rio Aripuanã e afluentes. **Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental**, p. 167-181, 2015.

TERRABRASILIS. **Desmatamento Unidades de Conservação**. Disponível em: < <http://terrabrasilis.dpi.inpe.br>>. Acesso em: set. 2022.

TYUKAVINA, Alexandra., POTAPOV, Peter., HANSEN, Matthew., PICKENS, Amy., STEHMAN, Stephen., TURUBANOVA, Svetlana., PARKER, Diana., ZALLES, Viviana., LIMA, André., KOMMAREDDY, Indrani., SONG, Xiao-Peng., WANG, Lei., HARRIS, Nancy. Global Trends of Forest Loss Due to Fire From 2001 to 2019. **Frontiers**, 2022.

USGS. **EarthExplorer**. 2022. Disponível em: <<https://earthexplorer.usgs.gov/>>. Acesso em: 10 de jan. de 2022.

VENTURA, Jonh., VASCONCELOS, Maicon. O Fogo como Processo Físico-Químico e Ecológico. **Incêndios Florestais em Portugal Impactes E Prevenção**, p. 93-113, 2006.

VERAS, Caio. Potencial presente e futuro de incêndios florestais induzidos por meteorologia no sudeste do Brasil. **Jornal Internacional de Climatologia**, p.1511-1532, 2021.

WENG, Qihao. **Remote Sensing and GIS Integration: Theories, Methods, and Applications**. McGraw-Hill. 2012.

WIDROW, Bernard., HOFF, Marcian. **Adaptive switching circuits**, 1960.

WWF. **Incêndios florestais**. 2019. Disponível em: <<https://www.worldwildlife.org/stories/forest-fires>>. Acesso em: 02 de fev. de 2022.

ZARA, A. V. LIMA, J. H. **Reservas extrativistas amazônicas e uso sustentável dos recursos florestais: um olhar sobre o caso da Resex Tapajós-Arapiuns**. In: Instituto do Homem e Meio Ambiente da Amazônia. 2004.