



UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO DE CIÊNCIAS AGRÁRIAS E ENGENHARIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

JEFERSON PEREIRA MARTINS SILVA

**MODELAGEM DE RISCOS DE INCÊNDIOS FLORESTAIS E OTIMIZAÇÃO DA
ALOCÇÃO DAS ESTRUTURAS DE COMBATE POR MEIO DE TÉCNICAS DE
INTELIGÊNCIA ARTIFICIAL**

JERÔNIMO MONTEIRO – ES

2023

JEFERSON PEREIRA MARTINS SILVA

**MODELAGEM DE RISCOS DE INCÊNDIOS FLORESTAIS E OTIMIZAÇÃO DA
ALOCÇÃO DAS ESTRUTURAS DE COMBATE POR MEIO DE TÉCNICAS DE
INTELIGÊNCIA ARTIFICIAL**

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.

Orientador: Dr. Gilson Fernandes da Silva

Coorientador: Dr. Juan Ramón Molina

Coorientador: Dr. Nilton Cesar Fiedler

JERÔNIMO MONTEIRO – ES

2023

Ficha catalográfica disponibilizada pelo Sistema Integrado de
Bibliotecas - SIBI/UFES e elaborada pelo autor

S586m Silva, Jeferson Pereira Martins, 1992-
MODELAGEM DE RISCOS DE INCÊNDIOS
FLORESTAIS E OTIMIZAÇÃO DA ALOCAÇÃO DAS
ESTRUTURAS DE COMBATE POR MEIO DE TÉCNICAS DE
INTELIGÊNCIA ARTIFICIAL / Jeferson Pereira Martins Silva.
2023.
83 f. : il.

Orientador: Gilson Fernandes Silva.
Coorientadores: Juan Ramón Molina, Nilton Cesar Fiedler.
Tese (Doutorado em Ciências Florestais) - Universidade
Federal do Espírito Santo, Centro de Ciências Agrárias e
Engenharias.

1. Proteção florestal. 2. Aprendizado de máquina. 3. Pesquisa
operacional. 4. Mudança climática. I. Silva, Gilson Fernandes.
II. Molina, Juan Ramón. III. Fiedler, Nilton Cesar. IV.
Universidade Federal do Espírito Santo. Centro de Ciências
Agrárias e Engenharias. V. Título.

CDU: 630*38

**MODELAGEM DE RISCOS DE INCÊNDIOS FLORESTAIS E OTIMIZAÇÃO DA
ALOCÇÃO DAS ESTRUTURAS DE COMBATE POR MEIO DE TÉCNICAS DE
INTELIGÊNCIA ARTIFICIAL**

JEFERSON PEREIRA MARTINS SILVA

Tese apresentada ao Programa de Pós-Graduação em Ciências Florestais do Centro de Ciências Agrárias da Universidade Federal do Espírito Santo, como parte das exigências para obtenção do Título de Doutor em Ciências Florestais na Área de Concentração Ciências Florestais.

Orientador: Dr. Gilson Fernandes da Silva

Coorientador: Dr. Juan Ramón Molina


Coorientador: Dr. Nilton Cesar Fiedler

Aprovada em 31 de agosto de 2023.




Dr. Gilson Fernandes da Silva (Orientador)

Universidade Federal do Espírito Santo




Dr. José Eduardo Macedo Pezzopane (Examinador interno)

Universidade Federal do Espírito Santo




Dr. Antônio Almeida de Barros Junior (Examinador interno)

Universidade Federal do Espírito Santo



Dr. André Quintão de Almeida (Examinador externo)

Universidade Federal de Sergipe



Dr. Evandro Ferreira da Silva (Examinador externo)

Universidade Federal do Pará

É impossível viver sem falhar em algo, a menos que você viva tão cautelosamente que é como se nem estivesse vivendo, o que também é um fracasso. ”

(J.K. Rowling)

AGRADECIMENTOS

Primeiramente, agradeço a Deus, que me orientou e me concedeu força e determinação para perseguir meus objetivos.

Aos meus queridos pais, Arlene e Manoel Vinícius, meus irmãos, Jessica e Vinicius, minha sobrinha, Alana, aos meus avós, tios e primos.

Agradeço a Taís, minha grande motivadora e companheira, seu apoio foi fundamental para a conclusão desta tese.

Ao meu orientador, Gilson Fernandes da Silva, pelo conhecimento compartilhado e pela orientação valiosa na elaboração desta tese.

Aos meus coorientadores, Juan Ramón e Nilton, agradeço pelas sugestões construtivas que enriqueceram este trabalho.

Ao professor Pezzopane, pelo aprendizado proporcionado e por ser uma inspiração profissional.

Estendo meus agradecimentos aos professores Antônio, André e Evandro, pela disponibilidade em integrar a banca examinadora.

Aos colegas e amigos do laboratório LaMFlor, agradeço pelo ambiente colaborativo e pelo suporte durante a elaboração desta pesquisa.

Aos queridos amigos que fiz durante meu período acadêmico aqui na UFES.

Agradeço a Universidade de Córdoba (UCO) e ao Laboratório de Incêndios Florestais (LABIF) por me acolherem durante o estágio do meu doutorado.

Por fim, expresso minha gratidão ao Programa de Pós-graduação em Ciências Florestais, à Universidade Federal do Espírito Santo, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e a Fundação de Amparo à pesquisa do Estado do Espírito Santo (FAPES).

RESUMO

SILVA, Jeferson Pereira Martins. **MODELAGEM DE RISCOS DE INCÊNDIOS FLORESTAIS E OTIMIZAÇÃO DA ALOCAÇÃO DAS ESTRUTURAS DE COMBATE POR MEIO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL**. 2023. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES. Orientador: Prof. Dr. Gilson Fernandes da Silva. Coorientador: Dr. Juan Ramón Molina; Dr. Nilton Cesar Fiedler.

Este estudo apresenta uma abordagem para a gestão de incêndios florestais com a integração de um sistema WebGIS e inteligência artificial. Para treinar o modelo de aprendizado profundo, foram coletados dados relacionados à vegetação, topografia, fatores antrópicos e registros históricos de incêndios para o ano de 2008 em Andaluzia, Espanha. O conjunto de dados foi devidamente normalizado e dividido em 70% para treinamento, 10% para validação e 20% para teste. Diversos algoritmos e funções de ativação foram avaliados, sendo que a combinação entre *Adam* e *Relu* obteve destaque, registrando uma acurácia de 0.86 durante o treinamento. Com base nesse modelo, foi gerado um mapa de risco. Ao aplicar o método *K-means* a este mapa, foram identificadas áreas de alto risco e sugeridos pontos centrais para a instalação de infraestruturas de combate a incêndios. Para validar a eficácia do modelo, as posições sugeridas foram comparadas com as localizações reais de aeronaves de combate a incêndios em Andaluzia, Espanha. Com 31 clusters e um limiar de risco de 0,75, a proximidade entre as coordenadas propostas e os reais foi notável, reforçando o potencial prático da abordagem proposta neste trabalho.

Palavras-chave: Proteção florestal, Aprendizado de máquina, Pesquisa operacional, Mudança climática.

ABSTRACT

SILVA, Jeferson Pereira Martins. **MODELING OF WILDFIRE RISKS AND OPTIMIZATION OF COMBAT STRUCTURE ALLOCATION THROUGH ARTIFICIAL INTELLIGENCE TECHNIQUES**. 2023. Thesis (Doctorate in Forestry Sciences) – Federal University of Espírito Santo, Jerônimo Monteiro, ES. Advisor: Prof. Dr. Gilson Fernandes da Silva. Co-adviser: Dr. Dr. Juan Ramón Molina; Dr. Nilton Cesar Fiedler.

This study presents an approach to wildfire management integrating a WebGIS system and artificial intelligence. To train the deep learning model, data related to vegetation, topography, anthropogenic factors, and historical fire records for the year 2008 in Andalusia, Spain were collected. The dataset was duly normalized and split into 70% for training, 10% for validation, and 20% for testing. Various algorithms and activation functions were evaluated, with the combination of Adam and Relu standing out, recording an accuracy of 0.86 during training. Based on this model, a risk map was generated. By applying the K-means method to this map, high-risk areas were identified, and central points for the installation of firefighting infrastructures were suggested. To validate the model's efficacy, the suggested positions were compared with the actual locations of firefighting aircraft in Andalusia, Spain. With 31 clusters and a risk threshold of 0.75, the proximity between the proposed coordinates and the actual ones was notable, reinforcing the practical potential of the approach proposed in this study.

Keywords: Forest protection, Machine learning, Operations research, Climate change.

LISTA DE FIGURAS

Figura 1- Anatomia de um incêndio Florestal.....	16
Figura 2 - Mapa de risco de incêndios florestais para a província de Lam Dong, Vietnã.	17
Figura 3- Comportamento de incêndios florestais em situações de declividade.	21
Figura 4 - Rede neural artificial.	25
Figura 5 - Interface do sistema WebGIS desenvolvido com a indicação das funcionalidades na barra lateral.	29
Figura 6 - Fluxograma contendo as etapas metodológicas descritas do item 4.1 ao item 4.8.	31
Figura 7 - Região de Andaluzia, Espanha.....	32
Figura 8 - Interface de inserção dos dados de entrada não automatizados no sistema WebGIS criado.....	34
Figura 9 - Interface do sistema WebGIS destinada a seleção das variáveis topográficas.....	35
Figura 10 - Interface do sistema WebGIS destinada a seleção das variáveis meteorológicas.....	37
Figura 11 - Interface do sistema WebGIS destinada a seleção das variáveis referentes a vegetação.....	38
Figura 12 - Variáveis utilizadas para confecção do modelo de Deep learning de estimativa de incêndios florestais.....	46
Figura 13 - Interface para inserção da área de estudo e das amostras para o treinamento de deep learning.....	48
Figura 14 - Interface para inserção da área de estudo e das amostras para o treinamento de deep learning.....	48
Figura 15 - Adicionando fatores relacionados a topografia.	49
Figura 16 - Adicionando fatores meteorológicos.	49
Figura 17 - Adicionando fatores relacionados a vegetação.....	50
Figura 18 - Correlação entre os fatores utilizados para treinar o modelo em Andaluzia.	51
Figura 19 - Frequência de ocorrência de incêndio de acordo com o (a) orientação do terreno e com o (b) uso e ocupação da terra.	53
Figura 20 - Frequência de ocorrência de incêndios com relação aos fatores analisados.	55
Figura 21 - Acurácia do treinamento e validação dos modelos de deep learning	

utilizados para predição de risco de incêndios florestais.....	59
Figura 22 - AUC e curva ROC para analisar a acurácia dos modelos de deep learning utilizados para prever o risco de incêndios.....	60
Figura 23 - Mapa de risco de incêndios para Andaluzia.....	61
Figura 24 - Comparação entre localizações das infraestruturas de combate (bases) e os centroides dos clusters formados	62
Figura 25 - Interface para treinamento e exibição do desempenho do modelo por meio de gráficos e estatísticas.	64
Figura 26 - Tela para visualização do mapa de risco gerado pelo modelo de deep learning.	64
Figura 27 - Exibição e cálculo do número de clusters.....	65
Figura 28 - Mapa de risco de incêndio florestal para o Brasil.....	66
Figura 29 - Mapa de risco de incêndio para o continente Africano.....	67
Figura 30 - Mapa de risco de incêndio florestal para a Austrália.....	68

LISTA DE TABELAS

Tabela 1 - Efeito da inclinação sobre a velocidade de propagação do fogo.	21
Tabela 2 - Estatísticas de treinamento e validação da <i>deep learning</i> utilizada para prever incêndios florestais.....	57

LISTA DE EQUAÇÕES

Equação 1	25
Equação 2	25
Equação 3	26
Equação 4	26
Equação 5	36
Equação 6	36
Equação 7	44
Equação 8	44
Equação 9	44
Equação 10	44

SUMÁRIO

1	INTRODUÇÃO	11
2	OBJETIVOS	13
	2.1 Objetivo Geral.....	13
	2.2 Objetivos Específicos	13
3	REVISÃO DE LITERATURA.....	14
	3.1 Comportamento dos Incêndios Florestais	14
	3.1.1 Formas de propagação	14
	3.1.2 Tipos de Incêndios	15
	3.1.3 Partes de um Incêndio Florestal.....	15
	3.2 Fatores de ignição	16
	3.3 Fatores meteorológicos	18
	3.4 Material combustível.....	18
	3.5 Fatores topográficos.....	20
	3.6 Distância das vias e residências.....	22
	3.7 Técnica de aprendizagem de máquinas.....	23
	3.8 Redes neurais artificiais	24
	3.9 Web e plataforma WebGIS.....	26
4	MATERIAL E MÉTODOS.....	29
	4.1 Área em estudo: Estrutura e criação do banco de dados.....	32
	4.2 Variáveis topográficas	34
	4.3 Variáveis meteorológicas	35
	4.4 Vegetação	37
	4.5 Normalização das Variáveis	38
	4.6 Adição das Bandas.....	39
	4.7 Construção e compilação do Modelo de <i>Deep Learning</i>	40
	4.8 Avaliação do Modelo	43
	4.9 Identificação dos locais para alocação das equipes de combate	43
	4.10 Transferência de aprendizado em modelos de previsão de risco de incêndio:	

uma análise comparativa entre Brasil, Austrália e o continente Africano	46
5 RESULTADOS E DISCUSSÃO	51
5.1 Transferência de aprendizado em modelos de previsão de risco de incêndio: uma análise comparativa entre Brasil, Austrália e o continente Africano	63
6 CONCLUSÃO.....	70
7 REFERÊNCIAS	71

1 INTRODUÇÃO

As florestas estão sujeitas a incêndios que causam danos significativos a sua estrutura, à biodiversidade e ao ciclo de nutrientes. Esses sinistros são considerados uma das principais causas da degradação dos ecossistemas florestais em todo o mundo e geram grandes perdas econômicas. As mudanças climáticas proporcionam maiores riscos de incêndios florestais, devido a diminuição de chuvas e aumento da temperatura. Além disso, intervenções humanas colaboram cada vez mais para a ocorrência desse evento (ARGAÑARAZ et al., 2015). Com isso, a recorrência de incêndios florestais vem aumentando de forma exacerbada em várias regiões do mundo (ARGAÑARAZ et al., 2015; ARPACI et al., 2014; LITTELL et al., 2016).

A maior parte dos incêndios florestais são consequências de ações antrópicas, intencionais ou negligenciais. Sabendo disso, as medidas de prevenção devem ser adotadas para evitar a ignição e a propagação, e estas devem ser prioritárias em áreas com maiores riscos de incêndios (ZEFERINO, 2020). Diversas abordagens foram propostas para modelar o comportamento do fogo, mas nem sempre fornecem bons resultados. Isso acontece porque o incêndio florestal é um processo complexo e não linear (TIEN BUI et al., 2017) e está relacionado a interação de vários fatores, a saber: tipo de vegetação, elevação, declividade, temperatura, precipitação e histórico de incêndios (SACHDEVA; BHATIA; VERMA, 2018).

Devido à complexidade do relacionamento entre a ignição e os fatores de ignição/propagação, diversas técnicas de aprendizagem de máquinas podem ser usadas na elaboração de mapas de riscos de incêndios (BAR MASSADA et al., 2013; TIEN BUI et al., 2017). Estas técnicas, aliadas as ferramentas de sistemas de informações geográficas (SIG), permitem avaliar diferentes fatores de risco e produzir mapas em nível regional ou nacional (POURTAGHI; POURGHASEMI; ROSSI, 2015), sendo de grande utilidade para o planejamento e suporte à decisão no gerenciamento de recursos no combate a incêndios florestais.

Levando em consideração um cenário pessimista de mudanças climáticas, a alocação dos diferentes recursos no combate a incêndios deve ser estrategicamente planejada, a fim de mitigar os impactos provocados em florestas nativas e plantadas. Com isso, diferentes técnicas de otimização podem ser aplicadas para auxiliar o planejamento estratégico e tático de recursos de combate aos incêndios florestais. Fernández; Falero; Pérez-González (2002) geraram um modelo para envio de diferentes recursos de combate a incêndios florestais com auxílio de mapas de risco.

HAKIMI (1964) desenvolveu modelos de otimização para localização ideal de instalações de emergências. Bookbinder; Martell (1979) trabalharam com teoria das filas para montar brigadas de helicópteros. Zeferino (2020) gerou um modelo para a localização de diferentes tipos de aeronaves de forma a maximizar a cobertura no combate a incêndios florestais.

Apesar dos avanços significativos na modelagem de risco de incêndios florestais e na otimização da alocação de recursos, acredita-se que ainda há espaço para melhorias na precisão e eficiência desses processos. Uma abordagem promissora é a aplicação de técnicas de agrupamento, como o algoritmo *k-means* para agrupar áreas de alto risco.

O *k-means* é uma técnica de aprendizado de máquina não supervisionada que tem sido aplicada em uma variedade de contextos, desde a segmentação de clientes em marketing até a detecção de anomalias em segurança de rede. No contexto de incêndios florestais, o *k-means* pode ser usado para agrupar os locais de maior risco. Os centroides desses agrupamentos, que representam os locais de maior risco dentro de cada grupo, podem então ser sugeridos como locais para a instalação de infraestruturas de combate a incêndios florestais.

Diante da complexidade dos sistemas ambientais, desenvolver modelos de extinção de incêndio em tempo real é um desafio. No entanto, é possível otimizar o desempenho dos recursos de combate a incêndios para reduzir as perdas. A tecnologia facilita isso por meio de um processo automatizado, o sistema WebGIS, que integra a geração de banco de dados, treinamento de modelos de aprendizado de máquina, geração de mapa de risco de incêndio, agrupamento com *k-means*, indicando locais propícios a instalação de infraestruturas de combate e prevenção. Esta automatização permite uma resposta rápida às mudanças advindas da dinâmica de uso e ocupação da terra e das mudanças climáticas.

2 OBJETIVOS

2.1 Objetivo Geral

Desenvolver e automatizar um sistema WebGIS que emprega inteligência artificial para classificar, agrupar e monitorar áreas de risco de incêndio, otimizando a alocação de recursos de combate.

2.2 Objetivos Específicos

- Gerar mapas de risco de incêndios florestais, considerando os fatores de ignição e propagação;
- Calibrar e validar os parâmetros de técnicas de aprendizado de máquina para a previsão de risco de incêndios florestais;
- Desenvolver um método para agrupar áreas de alto risco de incêndio e indicar locais para instalação de infraestruturas de combate;
- Automatizar o processo de criação de banco de dados, treinamento e avaliação do modelo de aprendizado de máquina, agrupamento e indicação de locais para infraestrutura de combate a incêndios, e;
- Desenvolver uma interface de usuário intuitiva para a aplicação do sistema WebGIS proposto.

3 REVISÃO DE LITERATURA

O fogo é um fenômeno natural intrínseco aos ecossistemas, afetando-os de diversas maneiras. Sua importância reside na criação e manutenção da estrutura da paisagem, bem como na composição, função e integridade ecológica de diversos ecossistemas florestais. Além disso, o fogo influencia as taxas e os processos de sucessão ecológica (MORGAN et al., 2001). Por outro lado, o fogo também pode ser um evento ambiental destrutivo, causando severas perdas de habitats, biodiversidade e paisagens. Esses incêndios podem ser provocados tanto por fatores naturais quanto antropogênicos (SEMERARO et al., 2016).

Nas últimas décadas, observou-se um aumento nas ocorrências de incêndios florestais, associado ao aquecimento global e a intensas atividades humanas (COTTER, 2009; EUGENIO et al., 2016; JULIUS et al., 2008). Isso destaca a importância de entender a dinâmica dos incêndios florestais, bem como as formas mais eficazes de combatê-los.

3.1 Comportamento dos Incêndios Florestais

3.1.1 Formas de propagação

De acordo com Barnes; Golakoff; Barnes (2004) e Soares; Batista (2007), para que um incêndio se propague, o calor deve ser transferido para o combustível ao redor. O ar circundante e o combustível são aquecidos pelo fogo, permitindo que ele se propague com mais facilidade. Existem três mecanismos de transferência de calor: convecção, radiação e condução. Todos os três contribuem de maneiras distintas para o processo de combustão, que varia dependendo do material combustível, da velocidade do vento e da inclinação do terreno.

Convecção é a transferência de calor por meio de movimento circular ascendente de massas de ar aquecidas. As correntes de convecção são frequentemente responsáveis pelo pré-aquecimento das camadas mais altas dos arbustos e das copas, carregando o fogo do solo para o alto das copas das árvores.

Radiação é a transferência de calor pelos raios solares ou pela chama, responsável pela maior parte do pré-aquecimento de combustíveis ao redor de um incêndio. A temperatura desses combustíveis pode aumentar tanto que inflamam

antes do contato com as chamas, espalhando o fogo ainda mais rapidamente.

Condução envolve a transferência de calor entre dois objetos que estão em contato físico direto. A condução, geralmente, não é um mecanismo eficaz de transferência de calor em incêndios florestais, isso porque a madeira é um mau condutor de calor. A compreensão desses mecanismos de transferência de calor é crucial para entender os diferentes tipos de incêndios florestais.

3.1.2 Tipos de Incêndios

Existem três tipos de incêndios florestais: incêndios subterrâneo, de copa e de superfície (GOVERNMENT OF CANADA, 2019; LYNDON; POMERANTZ; DONEV, 2019; SOARES, R.; BATISTA, 2007).

Os **incêndios subterrâneos** acontecem, geralmente, em solo de brejo, como turfas, devido ao acúmulo de material orgânico depositado e que sofreu ignição. Esses incêndios são os mais difíceis de detectar e de controlar, pois avançam produzindo pouca fumaça e sem a presença de chamas (SOARES, R. V.; BATISTA; TETTO, 2017). Possuem movimento lento, mas, quando deixados sem vigilância, podem destruir grandes áreas. Um exemplo desse tipo de incêndio aconteceu no Parque Estadual de Itaúnas, no município de Conceição da Barra, Espírito Santo (TV GAZETA, 2015). Na ocasião, o incêndio durou 18 dias e destruiu mais de 1,4 mil hectares de florestas nativas.

Os **incêndios de copa** queimam árvores por todo o comprimento até o topo. Estes são os incêndios florestais mais intensos e perigosos devido ao seu comportamento de rápida expansão. Eles se desenvolvem no topo das árvores e, em alguns casos, podem pular de uma árvore para outra.

Os **incêndios de superfície** são os mais comuns e são mais fáceis de serem combatidos, causando menos danos à floresta. Tais incêndios propagam-se queimando restos vegetais localizados na superfície da floresta como, folhas, galhos e gramíneas (SOARES, R. V.; BATISTA; TETTO, 2017).

3.1.3 Partes de um Incêndio Florestal

A propagação inicial do fogo teria formato circular e não mudaria se não fosse a influência de vários fatores. No caso de um incêndio ao ar livre, as condições climáticas e topográficas controlam e definem a forma e intensidade de propagação

dos incêndios (SOARES, R. V.; BATISTA; TETTO, 2017). Considerando um relevo plano, o vento seria o primeiro fator a manifestar influência, transformando a forma inicial de propagação de circular para elíptica, em que um dos setores se propagaria mais rapidamente do que os outros. Com essas condições mencionadas, o incêndio toma forma definida, compreendendo as partes mais importantes: cabeça, flancos, calda, vão, ponto de fogo e dedo (Figura 1) (RÁCZ, 2018).

A cabeça é a parte que avança mais rapidamente e segue a direção do vento; a cauda se propaga em direção oposta à cabeça, contra o vento; os flancos se propagam perpendicularmente à cabeça do incêndio; os dedos são áreas queimadas e alongadas que ficam projetadas no corpo principal do fogo, resultando em um perímetro irregular; o vão é um recuo no perímetro do incêndio localizado entre dois dedos (RÁCZ, 2018). A velocidade de propagação é sempre decrescente da cabeça para os flancos e para a calda.




Figura 1- Anatomia de um incêndio Florestal.

Fonte: Adaptado de RÁCZ (2018).

A prevenção dos incêndios florestais é mais econômica do que tentar eliminá-los e causa menos impacto às vidas, propriedades pessoais e ao meio ambiente (MARTÍNEZ; VEGA-GARCIA; CHUVIECO, 2009). Muitas variáveis ambientais, topográficas e antropogênicas são importantes para a ocorrência e propagação do fogo, e é preciso compreendê-las para entender e determinar o risco de incêndios.

3.2 Fatores de ignição

Parte importante na prevenção de incêndios é a avaliação de risco, uma vez

que os recursos de planejamento antes do incêndio necessitam de ferramentas objetivas para monitorar quando e onde um incêndio tem maior propensão para ocorrer ou quando irá causar maiores danos (CHUVIECO et al., 2010; GARCÍA et al., 2020). O risco de incêndio é uma combinação probabilística de um incêndio acontecer com o dano potencial que ele pode provocar, sendo que o primeiro é relacionado ao perigo de incêndio e o segundo com a vulnerabilidade (ESKANDARI; CHUVIECO, 2015).

Existem regiões onde a ocorrência de incêndios é mais frequente, por exemplo próximo a vilas e acampamentos, margens de rodovias, proximidades de áreas agrícolas e margens de rios e lagos. Da mesma forma, existem locais com poucas ocorrências de incêndios. Nesse sentido, a elaboração de mapas de riscos, por meio da marcação de pontos onde ocorrem os incêndios, possibilita a visualização das áreas de maior incidência de incêndios e ajuda na distribuição de recursos para medidas preventivas, especialmente, para áreas de maiores riscos (SOARES, R. V.; BATISTA; TETTO, 2017). Mapas de risco de incêndios (Figura 2) são gerados com base na análise de registros históricos de incêndios e fatores de ignição (BAR MASSADA et al., 2013; HIGUERA et al., 2015).




Figura 2 - Mapa de risco de incêndios florestais para a província de Lam Dong, Vietnã. Fonte: TIEN BUI et al. (2017).

3.3 Fatores meteorológicos

Os fatores que influenciam a ocorrência de incêndios florestais são aqueles que interferem na inflamabilidade do material combustível, como por exemplo a temperatura do ar, velocidade e direção do vento, precipitação e umidade relativa do ar.

A probabilidade de ocorrência e a propagação de incêndios é influenciada diretamente pela temperatura, tanto do ar atmosférico como do material combustível (SOARES, R. V.; BATISTA; TETTO, 2017), pois estas variáveis tornam os combustíveis mais secos e propícios a entrarem em ignição.

A precipitação é uma variável comumente utilizada nos mapas de risco de incêndios florestais (TIEN BUI et al., 2017), uma vez que pode aumentar a umidade do material combustível, dificultando a propagação do fogo (PRUDENTE, 2010). No entanto, longos períodos com seca fazem com que o material combustível ceda umidade para o ambiente, aumentando as chances para que ocorra ignição. Segundo (SOARES; BATISTA; NUNES, 2008), a taxa de propagação de incêndios florestais é menor quando a distribuição da precipitação é mais uniforme. Sabendo disso, a análise do efeito da precipitação deve considerar não apenas o volume de chuva acumulada, mas também sua sazonalidade.

3.4 Material combustível

A umidade do material combustível está relacionada à fisiologia da vegetação e variações no clima (CHUVIECO; KASISCHKE, 2007). A quantidade de água presente na vegetação é inversamente proporcional ao potencial de ignição, por isso, é considerada uma variável importante para estimar o risco de incêndios florestais (NELSON, 2001). Normalmente, são utilizadas os teores de umidades do material combustível, vivo e morto, para a elaboração dos mapas de risco, sendo que estes são estimados, em alguns estudos, por imagens de satélites (CHUVIECO et al., 2010; GARCÍA et al., 2020).

O combustível morto, serrapilheira, possui maior inflamabilidade porque são mais secos e são mais dependentes das mudanças atmosféricas do que os combustíveis vivos. Isso ocorre porque os combustíveis vivos possuem mecanismos para extrair água da reserva do solo e reduzir a evapotranspiração (CHUVIECO et al.,

2004).

O tipo de vegetação influencia no potencial de propagação dos incêndios. Por exemplo, a propagação é mais rápida em áreas com plantios de conífera comparada às áreas com plantios de folhosas, bem como é mais rápida em florestas comerciais do que em florestas naturais e mais rápida ainda em áreas com pastagens (SOARES, R. V.; BATISTA; TETTO, 2017). Em decorrência disso, classes de riscos de incêndios são criadas em função da inflamabilidade da vegetação. A caracterização da vegetação sob as diretrizes em que o fogo se comporta após a ignição é chamada de modelo de combustível. Ambientes SIG e imagens de satélite são bastante utilizados para a identificação de cada modelo de combustível associado a cada polígono (CHUVIECO et al., 2003).

As características físicas e químicas do material combustível determinam a possibilidade de ignição, sendo o ponto essencial para a proteção contra incêndios e o único com possibilidade de atuação preventiva direta. Os combustíveis florestais podem ser classificados conforme sua localização no estrato arbóreo e caracterizado conforme sua classe de tamanho, arranjo do material, massa, tipo de combustível e teor de umidade (BEUTLING et al., 2005).

A quantidade de material combustível define se o fogo vai ou não se propagar, seu comportamento e a intensidade de calor liberada pelo processo de combustão. O arranjo e continuidade desse material são fatores determinantes para a quantidade de oxigênio disponível para queima. Esses fatores quando somados às estações severas de fogo, aumentam a extensão, a severidade e a frequência dos incêndios florestais (WESTERLING, 2016).

O tipo de floresta influencia diretamente a propagação dos incêndios florestais. Florestas naturais densas com dossel fechado interceptam a radiação solar, o que reduz a temperatura do ar e do material combustível interno, bem como a velocidade do vento. Isso diminui o processo de evaporação, retardando a secagem da vegetação e tornando a propagação do fogo mais difícil.

Segundo Soares e colaboradores (2017), a própria transpiração da floresta aumenta a umidade relativa do ar diminuindo assim o risco de incêndio, bem como sua propagação ficaria bastante dificultada. Por outro lado, uma floresta aberta (floresta plantada) faria justamente o contrário, pois permitiria a livre passagem da radiação solar e das correntes de ar, produzindo aumento na temperatura da vegetação, facilitando a propagação de um incêndio florestal (HELBINGEN JÚNIOR, 2017).

Devido as características supracitadas, as florestas plantadas oferecem mais condições para a propagação dos incêndios florestais quando comparada as florestas naturais, em uma mesma região, principalmente, devido ao tipo de material combustível e da posição das árvores que facilitam a entrada e circulação do vento (SANTOS, 2020).

Uma técnica utilizada por algumas empresas florestais para reduzir e/ou amenizar os fatores citados é a cortina de segurança que altera a inflamabilidade do material combustível, implementando, em áreas com grandes extensões de florestas plantadas que possuem espécies altamente inflamáveis, sujeitas a incêndios de copa, faixas de espécies menos inflamáveis para reduzir a propagação de possíveis incêndios. A implantação de vegetação com folhagem menos inflamável é uma prática de silvicultura preventiva eficiente para reduzir a propagação do incêndio, pois dificulta o acesso do fogo às copas (MOTTA, 2008).

Desta forma, os plantios em mosaicos com espécies nativas, tais como as espécies designadas por “árvores bombeiras”, que não só são resistentes ao fogo como também contribuem para travar o avanço das chamas, para o caso das florestas de produção, é uma estratégia de prevenção aos incêndios florestais (CORREIA, 2017). Além do material combustível, os fatores topográficos também desempenham um papel crucial na propagação dos incêndios florestais.

3.5 Fatores topográficos

Fatores topográficos (inclinação, elevação e orientação do terreno) são considerados importantes na avaliação de risco de incêndios florestais (GHORBANZADEH et al., 2019). Por isso, são amplamente utilizados (KOLDEN; ABATZOGLOU, 2018; LAUTENBERGER, 2017). A declividade influencia na velocidade de propagação do fogo (GHORBANZADEH; BLASCHKE, 2018). O fogo se espalha mais rápido em situações de aclive do que em declives (KUSHLA; RIPPLE, 1997).

À medida que o grau de inclinação aumenta, a velocidade de propagação também aumenta. Isso ocorre porque a radiação e a convecção de um incêndio aquecem o material combustível não queimado a frente da chama, feito de forma mais rápida em situações de subidas (FIEDLER; SANT’ANNA; RAMALHO, 2020; NOLAN et al., 2017). Um aumento de 10 graus na inclinação resulta em uma duplicação da velocidade do fogo, sendo que a velocidade do fogo, em uma inclinação de 20 graus,

pode ser até quatro vezes mais rápida do que em um terreno plano (Figura 3) (SOARES, R. V.; BATISTA; TETTO, 2017).




Figura 3- Comportamento de incêndios florestais em situações de declividade.

Fonte: Adaptado de Nolan et al. (2017).

Estudos realizados no sudoeste dos Estados Unidos com queima controlada encontraram velocidades do fogo de 20 a 30 m.h⁻¹ nos declives e com 158 a 198 m.h⁻¹ nos aclives (SOARES, R. V.; BATISTA; TETTO, 2017). Experiências realizadas em laboratórios com queimas de acículas colocadas e diversos graus de inclinação (Tabela 1) mostraram um aumento na taxa de propagação menores do que mencionado acima.

Tabela 1 - Efeito da inclinação sobre a velocidade de propagação do fogo.

Inclinação (%)	Fator de propagação
[5; 15)	1,00
[16; 25)	1,05
[26; 35)	1,15
[36; 45)	1,25
[46; 55)	1,25

Fonte: Soares; Batista (2007).

É relevante mencionar também que, a declividade tem um efeito importante na supressão do fogo, porque afeta a fadiga da tripulação, o material rolante necessário para o combate e a segurança dos combatentes (CHUVIECO; CONGALTON, 1989).

A direção da montanha em relação aos pontos cardeais influencia na ocorrência e propagação de um incêndio (SOARES, R.; BATISTA, 2007). Encostas voltadas para o norte no hemisfério sul recebem a maior parte de radiação solar durante o ano, conseqüentemente, transmitem mais calor para essa exposição do que para Oeste, Leste e Sul (FIEDLER; SANT'ANNA; RAMALHO, 2020). A face que

menos recebe energia solar é a face Sul (hemisfério sul). Cabe citar que, em latitudes maiores que $23^{\circ}27'$, a face sul não recebe insolação direta, devido à inclinação do eixo da terra em relação ao sol, comprovando que o efeito da exposição aumenta de acordo com o aumento da latitude (FIEDLER; SANT'ANNA; RAMALHO, 2020; SOARES, R.; BATISTA, 2007).

A quantidade de calor incidente de forma diferente em cada face de exposição provoca efeitos diferentes no potencial de perigo de cada uma delas (FIEDLER; SANT'ANNA; RAMALHO, 2020). Por exemplo, as faces de exposição Norte recebem mais energia solar, por isso são mais quentes, possuem menor umidade relativa e o material combustível seca mais rapidamente quando comparadas as encostas voltadas para o Sul (SAYAD; MOUSANNIF; AL MOATASSIME, 2019). Obviamente, faces voltadas para o Norte possuem maiores riscos de incêndios.

A altitude é considerada um dos fatores mais importantes na propagação de incêndios florestais, porque está ligada a temperatura, precipitação e é relacionada também com a estrutura da vegetação (ADAB; KANNIAH; SOLAIMANI, 2013). Geralmente, altitude mais altas estão relacionadas a maior disponibilidade de chuva (CHUVIECO; CONGALTON, 1989; ŞEN; HABIB, 2000). De maneira invertida, uma elevação mais alta leva uma temperatura mais baixa (SOARES, R.; BATISTA, 2007).

Baixas elevações apresentam estações de perigo de incêndios mais longas do que altas elevações. Isso acontece porque, superfícies da terra com altas elevações apresentam ar mais rarefeito e temperaturas mais baixas (SOARES, R. V.; BATISTA; TETTO, 2017). Além disso, a elevação tem influência na propagação do fogo em curto espaço de tempo, devido a sua associação com o comportamento do vento. Os ventos próximos à superfície terrestre são fortemente influenciados pelo perfil do relevo e pelos processos locais de aquecimento e resfriamento (SOARES, R. V.; BATISTA; TETTO, 2017).

Topos de montanhas e fundos de vales apresentam diferentes propagações de incêndios durante um período de 24 horas, devido às correntes de vento, condições de temperatura e a umidade predominante nos dois locais. Durante o dia, os fundos de vale apresentam maior potencial de propagação e, à noite, os topos de montanhas possuem o maior potencial de propagação (SOARES, R.; BATISTA, 2007). Por fim, os incêndios tendem a ser menos graves em altitudes mais altas (CHUVIECO; CONGALTON, 1989).

3.6 Distância das vias e residências

A crescente incidência de incêndios ao redor do mundo tem impulsionado a pesquisa em modelagem da ocorrência de incêndios de origem antropogênica. Costafreda-Aumedes, Comas e Vega-García (2017) destacam que uma compreensão mais profunda dos fatores subjacentes é essencial para a tomada de decisões operacionais e planejamento estratégico de prevenção.

A distância das vias e estradas é fator importante no mapeamento de risco (CHUVIECO; CONGALTON, 1989), já que a ocorrência de incêndios florestais tem relação direta com a proximidade de vias (MOTA et al., 2019). A relação entre a ocorrência de incêndios e a distância de vias e/ou residências foram relatadas em diversos estudos científicos (MOLLICONE; EVA; ACHARD, 2006; VASILAKOS et al., 2007; YANG et al., 2007).

Devido à crescente preocupação global com incêndios, muitos dos quais são causados por atividades humanas, modelos de risco de incêndios foram desenvolvidos (COSTAFREDA-AUMEDES; COMAS; VEGA-GARCIA, 2017). Tais estudos são baseados em informações cartográficas e estatísticas sobre incêndios, processadas por meio de Sistemas de Informação Geográfica.

Áreas próximas a sistemas de transporte apresentam maiores taxas de atividade humana. Com isso, áreas com florestas próximas aos sistemas de transporte devem ser consideradas mais propensas a incêndios, porque a acessibilidade para humanos é mais intensa (CHUVIECO; CONGALTON, 1989). Entretanto, deve ser considerado também que as estradas ou vias têm efeito de quebra fogo ou caminhos por onde os veículos se locomovem para suprimir o fogo durante a ocorrência, diminuindo a dificuldade de extinção (RODRÍGUEZ Y SILVA et al., 2020).

3.7 Técnica de aprendizagem de máquinas

O progresso feito nos últimos anos na ciência relacionada ao manejo de fogo, especialmente aplicado à proteção contra incêndios florestais, juntamente com o aumento da potência oferecida pelos computadores integrados aos processos matemáticos, levou a importantes desenvolvimentos no campo da simulação da dinâmica de incêndios florestais (SILVA et al., 2013). Com isso, o uso de técnicas estatísticas para estimar o risco de incêndio florestal tornou-se uma abordagem comum.

Abordagens alternativas para prever o risco de incêndio florestal são baseadas

em sistemas de aprendizado de máquina que aprendem com os dados disponíveis. Goldarag; Mohammadzadeh; Ardakani (2016), por exemplo, usaram redes neurais multicamadas para classificar a presença ou ausência de fontes de calor nas regiões do Irã. Matin et al. (2017) propuseram modelos de risco ou perigo de incêndio selvagem, cujos parâmetros são estimados empiricamente usando muitas variáveis de entrada georreferenciadas.

Juvanhil (2017) trabalhou com aplicação de árvore de decisão e técnicas de sistemas de informações geográficas e sensoriamento remoto para a predição de incêndios florestais. Um total de doze variáveis, abrangendo aspectos ambientais, físicos e socioeconômicos, foram usadas para estimar o risco. Os resultados demonstraram que a árvore de decisão representa uma ferramenta viável para avaliar e representar o risco de incêndios florestais.

Ramalho et al. (2021) propuseram uma metodologia para a alocação estratégica de reservatórios de água no combate a incêndios florestais, considerando o risco de ocorrência. O estudo utilizou técnicas como lógica Fuzzy e análise de rede para identificar áreas de risco e otimizar a localização dos pontos de coleta. Esta abordagem visa melhorar a eficácia das estratégias de combate a incêndios em áreas de conservação e interesse econômico.

3.8 Redes neurais artificiais

Uma rede neural artificial (RNA) é um modelo computacional biologicamente inspirado, constituído por elementos de processamento simples, os neurônios artificiais, que estão dispostos em camadas e ligados entre si, sendo estas conexões denominadas de pesos sinápticos. Cada neurônio possui uma unidade de processamento que calcula certos tipos de funções matemáticas, normalmente não-lineares (BRAGA, A.; FERREIRA; LUDERMIR, 2007). Existem várias funções matemáticas utilizadas como funções de ativação, sendo as mais comuns a função linear, função rampa, função degrau e a função sigmoidal (BRAGA, A.; FERREIRA; LUDERMIR, 2007; HAYKIN, 2003).

O poder computacional da rede é extraído da sua estrutura paralela e distribuído. Com isso, possui habilidade de aprender e generalizar o conhecimento adquirido, tornando-a capaz de solucionar problemas complexos. Haykin (2003) define redes neurais artificiais como um processador distribuído, maciçamente paralelo, com capacidade de armazenar conhecimento e torná-lo disponível.

A arquitetura da rede refere-se ao formato como os neurônios estão estruturados e suas conexões, a quantidade de neurônios, o número de camadas e a forma como os sinais estão sendo propagados (*feedforward* ou *recorrentes*) (BRAGA, A.; FERREIRA; LUDERMIR, 2007; HAYKIN, 2003). O conhecimento da RNA do tipo *feedforward* é armazenado nas conexões entre unidades de processamento (pesos sinápticos), que são obtidos por um processo de adaptação ou aprendizagem (BRAGA, A.; FERREIRA; LUDERMIR, 2007). A estrutura de uma RNA do tipo *feedforward* é apresentada na Figura 4.




Figura 4 - Rede neural artificial.

Fonte: adaptado de Simões; Shaw (2007).

A camada de entrada é responsável por receber os sinais de entrada x_i . Cada entrada (x_i) é multiplicada por pesos sinápticos (w_{ij}) na camada intermédia, e posteriormente, ocorre a soma das entradas ponderadas, incluindo o bias (b_i), que serve para aumentar ou diminuir a entrada líquida da função de ativação (Equação 1).

$$a_j = \sum_{i=1} (x_i w_{ij}) + b_i \quad \text{Equação 1}$$

O somatório das entradas ponderadas (a_j) é transformado por uma função de ativação normalmente não-linear, por exemplo, a função logística (Equação 2) ou a tangente hiperbólica (Equação 3). O intervalo padronizado destas funções é de 0 a 1 ou de -1 a 1, respectivamente (HAYKIN, 2003).

$$c_j = \frac{1}{1 + e^{-a_j}} \quad \text{Equação 2}$$

$$c_j = \frac{e^{a_j} + e^{-a_j}}{e^{a_j} - e^{-a_j}} \quad \text{Equação 3}$$

Depois que passa pela camada intermediária o valor de c_j se torna entrada do neurônio da camada de saída. Cada valor de c_j é multiplicado por pesos sinápticos (ω_{jk}), e posteriormente, ocorre a soma das entradas ponderadas junto com o bias (Equação 4).

$$Y_k = d_k = \sum (c_j \omega_{jk} + b_k) \quad \text{Equação 4}$$

Em que $\hat{Y}_k$ = saída estimada; b_k = bias.

O passo seguinte é calcular o erro e corrigir os pesos com algoritmo de aprendizagem. Os algoritmos mais comuns são: *Backpropagation*, *resilient-propagation* e o *Levenberg-Marquardt*.

Os pesos sinápticos das conexões são ajustados entre os neurônios, a cada novo exemplo apresentado à rede, possibilitando-a responder mais corretamente a outras situações na fase de teste (BRAGA, A.; FERREIRA; LUDERMIR, 2007; HAYKIN, 2003). No processo de treinamento, deve ser evitado que a rede seja mais complexa do que o necessário, pois, pode ocorrer excesso de ajuste (*overfitting*), em que a rede modela relações indesejáveis, como o ruído (BARBALHO, 2001). Esse problema pode ser contornado fazendo simulações com arquiteturas diferentes, de formar a escolher a que possuir configuração mais simples, com menor número de neurônios e camadas.

Outro ponto importante é que pode provocar *overfitting* é o treinamento demasiado, que ocorre quando o número de iterações é superior ao necessário, o que leva a adaptação da rede à característica específicas dos dados utilizados durante a fase de treinamento (BRAGA, A. de P., 2007; HAYKIN, 2003). Para evitar este efeito, pode ser adotado o método de treinamento com parada antecipada. Nesse método é possível identificar o excesso de ajuste por meio da validação cruzada (*cross validation*), em que o banco de dados é dividido em uma amostra para o treinamento da rede e outra é utilizada para a validação cruzada após cada iteração (HAYKIN, 2003).

Inserir

3.9 Web e plataforma WebGIS

Desde o surgimento da Web 2.0, o usuário tem a capacidade não apenas de receber previamente o conteúdo disponibilizado por um número limitado de autores (Web 1.0), mas também de interagir com mapas online personalizados (ATABEKOVA; BELOUSOV; SHOUSTIKOVA, 2015). Introduzido pelo *Open Geospatial Consortium* (OGC), um padrão de servidor de mapeamento da Web (WMS), bem como a interface API do Google, permite aos usuários integrarem várias fontes de dados geográficos e criar mapas on-line (ERLE; GIBSON; WALSH, 2005; PURVIS; SAMBELLS; TURNER, 2006). Atualmente, o mapeamento na Web 2.0 é expresso como Sistemas de Informação Geográfica de Participação Pública, do inglês, *Public Participation Geographic Information Systems* (PPGIS).

Inicialmente, os webmaps 2.0 foram utilizados apenas no final de um processo de pesquisa para visualização dos resultados. À medida que os dados científicos são visualizados de maneira dinâmica ou fornecidos com estatísticas detalhadas, os mapas on-line tornaram-se parte da pesquisa fluxo de trabalho (ZASTROW, 2015). Além dos recursos de leitura e/ou gravação da Web 2.0, uma nova capacidade de inferir surgiu como o recurso do estágio inicial da Web 3.0 (MAVRIDIS; SYMEONIDIS, 2015), também conhecido como Web Semântica (MORRIS, 2011). Isso traz uma nova perspectiva para aplicativos de mapeamento, passando da coleta, exibição e comparação de variáveis espaciais para análise e modelagem de dados espaciais, surgindo a WebGIS.

WebGIS é a abreviação para Sistema de Informação Geográfica (*Geographic Information System - GIS*) baseado na web. Um WebGIS combina elementos de sistemas de informação geográfica tradicionais com tecnologia web, permitindo que os usuários acessem e interajam com dados geográficos em tempo real pela internet. Isso significa que as informações geográficas podem ser compartilhadas e colaboradas em tempo real, facilitando o trabalho em equipe e a tomada de decisões baseada em dados (CHMIELEWSKI et al., 2018; MUDI et al., 2021).

As principais características de um WebGIS incluem (BAKER, 2015; MATHIYALAGAN et al., 2005) :

- Visualização de mapas: Os usuários podem visualizar mapas interativos em um navegador da web, permitindo a exploração de dados geográficos em diferentes escalas e níveis de detalhes.
- Consulta e pesquisa: É possível fazer consultas e pesquisas sobre dados espaciais para obter informações específicas. Por exemplo, pesquisar por um endereço ou encontrar locais próximos a determinada área.

- **Análise espacial:** Os usuários podem realizar análises espaciais, como sobreposição de camadas de dados, cálculos de distância e análises de padrões. Isso permite a extração de informações valiosas a partir dos dados geográficos.
- **Compartilhamento de informações:** Um WebGIS facilita o compartilhamento de dados geográficos e análises com outras pessoas. Isso pode ocorrer por meio do envio de links para mapas específicos, exportação de dados ou compartilhamento de aplicativos GIS completos.
- **Colaboração:** Os usuários podem colaborar em projetos geográficos, compartilhando informações, adicionando comentários, realizando edições e trabalhando em conjunto em tempo real.
- **Integração com outras fontes de dados:** Um WebGIS pode integrar dados geográficos com outras fontes de informações, como bancos de dados, imagens de satélite, dados meteorológicos e dados demográficos. Isso amplia as possibilidades de análise e tomada de decisões.

Em resumo, o WebGIS é uma ferramenta poderosa para trabalhar com dados geográficos pela internet, permitindo que os usuários visualizem, analisem e compartilhem informações espaciais de maneira eficiente e colaborativa (MUDI et al., 2021) o que a torna uma ferramenta adequada para o monitoramento de incêndios florestais promovendo agilidade no reconhecimento de áreas com maior risco de ocorrência e na identificação de focos.

4 MATERIAL E MÉTODOS

Este estudo descreve o desenvolvimento de um sistema WebGIS, baseado na linguagem Python, projetado para estimar o risco de ocorrência de incêndios florestais e efetuar a alocação de infraestrutura de combate na região de interesse (Figura 5). Como exemplo prático da aplicação do sistema WebGIS desenvolvido, utilizou-se a província de Andaluzia na Espanha. A escolha de Andaluzia para o estudo foi devido a suas características geográficas, climáticas e bióticas, o que torna possível avaliar a eficiência do modelo de previsão de incêndios florestais e alocação de recursos para o combate. Além disso, a região apresenta um alto risco de ocorrência de incêndios florestais, fazendo com que políticas de predição, planejamento e combate sejam de grande importância social e ambiental.




Figura 5 - Interface do sistema WebGIS desenvolvido com a indicação das funcionalidades na barra lateral.

A metodologia proposta (Figura 6) criou mecanismos de obtenção de dados de forma automática do *Google Earth Engine* e os organizou na interface do sistema dentro de diferentes categorias: variáveis topográficas, variáveis meteorológicas e vegetação. Além dessas variáveis, o sistema criado exige apenas quatro tipos de dados de entrada não automatizados, o que simplifica a interface do usuário e torna o sistema mais intuitivo e adaptado a diferentes contextos. Os dados de entrada necessários são: (1) o arquivo em formato shapefile da área de estudo, (2) amostras em formato vetorial de ponto de fogo (identificado como classe 1) e não fogo (identificado como classe 0), (3) distância euclidiana das estradas e (2) distância

euclidiana das residências. Esses dados podem ser carregados a partir do computador do usuário ou do Asset.

A distância euclidiana, uma medida direta da distância linear entre dois pontos no espaço, é utilizada neste contexto para representar a proximidade das estradas e das residências. Essas medidas são essenciais para a estimativa do risco de incêndio, já que a proximidade a estradas e residências pode aumentar a probabilidade de ocorrência de incêndios por meio das atividades humanas.

As amostras de locais de fogo e não fogo são utilizadas para calibrar o modelo de risco de incêndio, fornecendo uma base de dados para identificar características comuns em áreas propensas a incêndios e áreas não propensas. Isso permite ao modelo distinguir entre áreas de alto e baixo risco.

O arquivo *shapefile* da área de estudo define os limites geográficos do local de análise. Este é um formato comum em sistemas de informação geográfica (SIG) e fornece uma maneira padronizada de especificar a área de estudo.

O sistema descrito nesta tese oferece uma maneira eficiente e acessível de estimar o risco de incêndio florestal e alocar recursos para o combate. Sua facilidade de uso e capacidade de adaptar-se a diferentes contextos geográficos podem torná-lo uma ferramenta valiosa para gestores de recursos florestais, urbanos e de emergência em todo o mundo.




Figura 6 - Fluxograma contendo as etapas metodológicas descritas do item 4.1 ao item 4.8.

4.1 Área em estudo: Estrutura e criação do banco de dados.

Como dito anteriormente, a área utilizada para exemplificação do modelo WebGIS é a região de Andaluzia, na Espanha (Figura 7).




Figura 7 - Região de Andaluzia, Espanha.

A Região da Andaluzia, situada no sul da Espanha, abrange uma posição geográfica na península ibérica entre as longitudes 2.0° W e 7.4° W e as latitudes 36.0° N e 38.5° N. O clima da região é mediterrâneo, com temperaturas que variam de maneira significativa ao longo do ano, tendo verões quentes e secos e invernos

temperados com precipitações relativamente elevadas (HERRERA-GRIMALDI et al., 2018).

Os dados de entrada não automatizados necessários para o sistema WebGIS criado foram obtidos da seguinte forma (Figura 8):

1. Área em estudo: O arquivo vetorial da área de estudo foi fornecido pelo Laboratorio de Incendios Forestales da Universidade de Córdoba (LABIF-UCO) em formato vetorial do tipo polígono foi armazenado no Asset e inserido no sistema WebGIS.
2. Amostras de fogo e não fogo: As amostras de fogo foram fornecidas pelo LABIF-UCO em formato vetorial do tipo ponto referentes ao ano de 2008 em um total de 2016 ocorrências de incêndios florestais. As amostras de não fogo foram aleatorizadas sobre áreas não vegetadas com base no uso e ocupação da terra e utilizando o arquivo vetorial da área em estudo (Andaluzia) como delimitador dos pontos aleatorizados. Além disso, para se evitar tendenciosidades foram utilizados número iguais de pontos de fogo e não fogo. Os pontos de fogo e não fogo foram unidos pela ferramenta Merge e criou-se na tabela de atributos uma coluna denominada “classe” onde foi atribuído valor 1 para os pontos de fogo e valor 0 para os pontos de não fogo. Por fim, o arquivo vetorial contendo os pontos de fogo e não fogo foi armazenado no Asset e inserido no sistema WebGIS.
3. Distância euclidiana das estradas: O arquivo vetorial do tipo linha das estradas existentes em Andaluzia foi fornecido pelo LABIF-UCO e sobre este arquivo foi calculada a distância euclidiana das estradas por meio da função *ee.Kernel.euclidean* no *Google Earth Engine*, utilizando como delimitador da área de cálculo o polígono de Andaluzia. Em seguida, o arquivo raster da distância euclidiana das estradas foi armazenado no Asset do *Google Earth Engine* e inserido no WebGIS, vale ressaltar que o sistema também permite a inserção via arquivo armazenado no computador do usuário.
4. Distância euclidiana das residências: O arquivo vetorial do tipo ponto das residências existentes em Andaluzia foi fornecido pelo LABIF-UCO e sobre este arquivo foi calculada a distância euclidiana das residências por meio da função *ee.Kernel.euclidean* no *Google Earth Engine*, utilizando como delimitador da área de cálculo o polígono de Andaluzia. Semelhante ao ocorrido com a distância euclidiana das estradas, a distância euclidiana das

residências foi armazenada no Asset e inserido no sistema WebGIS.



Figura 8 - Interface de inserção dos dados de entrada não automatizados no sistema WebGIS criado.

4.2 Variáveis topográficas

As variáveis referentes à topografia utilizadas para estimar o risco de incêndios incluem o Modelo de Elevação Digital (MDE), a Inclinação e a orientação do terreno. O MDE foi adquirido do conjunto de dados “USGS/SRTMGL1_003”, disponibilizado pela *U.S. Geological Survey* (USGS). Esse conjunto de dados é derivado da missão *Shuttle Radar Topography Mission* (SRTM) e possui uma resolução espacial de 30 metros.

As métricas de inclinação e orientação do terreno foram calculadas a partir do MDE utilizando as funções '*ee.Terrain.slope*' e '*ee.Terrain.aspect*' da biblioteca *Google Earth Engine*, respectivamente. A inclinação representa a taxa de mudança de elevação para cada célula de pixel, enquanto a orientação do terreno identifica a direção para a qual uma célula de pixel está orientada.

A visualização e a inserção das variáveis topográficas no sistema WebGIS foram automatizadas (Figura 9), permitindo sua obtenção para qualquer região, com base no vetor da área em estudo. Ao selecionar qualquer uma das três variáveis topográficas, o sistema faz o pré-processamento e disponibiliza a variável para visualização, fundamentando-se no centroide da referida área em estudo.




Figura 9 - Interface do sistema WebGIS destinada a seleção das variáveis topográficas.

4.3 Variáveis meteorológicas

Os dados referentes as variáveis meteorológicas foram obtidas a partir do conjunto de dados “IDAHO_EPSCOR/TERRACLIMATE” disponibilizado na plataforma do *Google Earth Engine*. O *TerraClimate* é uma base de dados de variáveis climáticas e hídricas que proporciona uma escala espacial de aproximadamente 4 quilômetros (1/24 graus), abrangendo o período de 1958 até o ano de 2022 em escala mensal.

O conjunto de dados foi filtrado para o período de 2008, e a média das variáveis para esse período foi calculada. Posteriormente, os dados foram reprojeto para a projeção da região em estudo com uma escala de 500 metros.

Foram selecionadas as seguintes variáveis do conjunto de dados do *TerraClimate*: temperatura máxima (Tmax), temperatura mínima (Tmin), precipitação acumulada (Ppt), umidade do solo (URsoil), e velocidade do vento (Ws). Os valores das variáveis foram convertidos para as unidades corretas por meio da multiplicação por um fator de escala e, em seguida, recortados para a área de estudo, com base no arquivo vetorial inserido no sistema WebGIS.

A base de dados *TerraClimate* não possui a umidade relativa do ar (UR). Quando o ar está saturado, a pressão exercida pelo vapor d’água é chamada de pressão máxima de vapor d’água (e_s) e como é função da temperatura, pode ser calculada através da *Equação 5* proposta por Tetens (TETENS, 1930). Para o cálculo

da pressão máxima de vapor d'água foi utilizada a temperatura máxima do ar obtida no *TerraClimate*.

$$e_s = 610,8 * \exp[(17,3 * T_{ar}) / (237,3 + T_{ar})] \quad \text{Equação 5}$$

Em que:

e_s é a pressão máxima de vapor d'água (kpa), e;

T_{ar} é a temperatura do ar (°C).

Como a umidade relativa do ar é a razão, em porcentagem, entre a quantidade de vapor d'água que o ar contém e a quantidade máxima que poderia conter à mesma temperatura, utilizamos a Equação 6 para obtenção da umidade relativa. Para o cálculo da umidade relativa do ar foi utilizada a pressão atual de vapor (e_a) obtida no *TerraClimate*.

$$UR = \frac{e_a}{e_s} * 100 \quad \text{Equação 6}$$

Em que:

UR é a umidade relativa do ar (%);

e_a é a pressão atual de vapor d'água (kpa), e;

e_s é a pressão máxima de vapor d'água (kpa).

A inserção, visualização e cálculo das variáveis meteorológicas no sistema WebGIS foram automatizadas (Figura 10), permitindo sua obtenção para qualquer região, com base no vetor da área em estudo. Ao selecionar qualquer uma das seis variáveis meteorológicas (temperatura máxima (Tmax), temperatura mínima (Tmin), precipitação acumulada (Ppt), umidade do solo (URsoil), velocidade do vento (Ws) e umidade relativa do ar (UR)), o sistema faz o pré-processamento e disponibiliza a variável para visualização, fundamentando-se no centroide da referida área em estudo.




Figura 10 - Interface do sistema WebGIS destinada a seleção das variáveis meteorológicas.

4.4 Vegetação

As variáveis referentes a vegetação utilizadas foram o Índice de Vegetação da Diferença Normalizada (NDVI), o Índice de Área Foliar (IAF) e o Uso e Ocupação da Terra (UOT). Os dados do Índice de Vegetação por Diferença Normalizada (NDVI) foram obtidos a partir do conjunto de dados “MODIS/006/MOD13Q1”, disponibilizado pela NASA no *Google Earth Engine*. O produto MODIS, MOD13Q1, fornece imagens de 16 dias em uma resolução de 250 metros. Para o período de estudo definido no ano de 2008, o conjunto de dados foi filtrado para incluir apenas imagens dentro da data especificada. A média do NDVI foi calculada para o período de um ano e, em seguida, recortada para a área em estudo. Posteriormente, o NDVI foi reprojetoado e recortado para a área em estudo, utilizando uma escala de 500 metros.

Os dados do Índice de Área Foliar foram adquiridos a partir do conjunto de dados “MODIS/006/MOD15A2H”, que é um produto MODIS e fornece estimativas de IAF em uma resolução de 500 metros. Os dados de IAF foram filtrados para o ano de 2008 e a média foi calculada para o período de um ano. Finalmente, os dados de IAF foram reprojetoados para a área em estudo com uma resolução de 500 metros e recortados.

O Uso e Ocupação da Terra foi derivado do conjunto de dados “ESA/GLOBCOVER_L4_200901_200912_V2_3”. O *GlobCover* 2009 é um mapa global de uso e ocupação da terra baseado nos dados do Espectrômetro de Imagem

de Média Resolução (MERIS) Nível 1B do ENVISAT adquiridos com uma resolução espacial de aproximadamente 300 metros. O produto fornece uma classificação detalhada do uso e ocupação da terra, incluindo florestas, pastagens, áreas urbanas, corpos d'água, entre outros. Posteriormente, o UOT foi reprojetado e recortado para a área em estudo.

Assim como as demais variáveis, as variáveis referentes à vegetação são adquiridas, inseridas e visualizadas de forma automatizada no sistema WebGIS, com base no vetor da área em estudo (Figura 11). O sistema realiza o pré-processamento e disponibiliza as variáveis para visualização, baseando-se no centroide da área em questão.




Figura 11 - Interface do sistema WebGIS destinada a seleção das variáveis referentes a vegetação.

4.5 Normalização das Variáveis

A normalização das variáveis foi a primeira etapa para criação do modelo de risco de incêndio e alocação da infraestrutura de combate, as etapas executadas anteriormente foram para confeccionar o banco de dados e os painéis de visualização do sistema WebGIS.

A normalização de dados é uma etapa importante em *deep learning* e *machine learning*. Ela envolve escalar os dados para um intervalo específico (0 e 1 ou -1 e 1), evitando disparidades de escala e acelerando a convergência durante o treinamento. A normalização melhora o desempenho, permite lidar com diferentes unidades de medida e garante que todos os recursos tenham uma faixa comparável.

O sistema WebGIS desenvolvido foi programado para identificar os valores mínimo e máximo de cada conjunto de dados na área em estudo, utilizando a função '*reduceRegion*' do *Google Earth Engine*, automaticamente.

Cada conjunto de dados foi processado de acordo com um conjunto de regras condicionais. Se um valor era menor ou igual ao valor mínimo, ele era substituído por 0. Se um valor estava entre o valor mínimo e o máximo, ele era normalizado para um valor entre 0 e 1, com base na sua posição relativa entre o valor mínimo e o máximo. Se um valor era maior ou igual ao valor máximo, ele era substituído por 1.

Finalmente, cada conjunto de dados normalizado foi escalonado para uma resolução espacial de 500 metros. Os conjuntos de dados processados dessa maneira foram: Inclinação, Modelo de Elevação Digital (MDE), orientação do terreno, Temperatura máxima (Tmax), Temperatura mínima (Tmin), Precipitação acumulada (Ppt), Umidade do solo (URsoil), Velocidade do vento (Ws), Umidade do ar (UR), Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Área Foliar (IAF), Distância euclidiana das estradas e Distância euclidiana das residências.

A normalização para o uso e ocupação da terra foi realizada de maneira diferente. As categorias de uso e ocupação da terra foram isoladas a partir desta imagem de classificação utilizando uma série de operações condicionais. Cada categoria de uso e ocupação da terra foi tratada de forma independente e a função retornou uma nova imagem para cada categoria, onde o pixel recebeu o valor 1 se pertencia à categoria e valor 0, caso contrário. As categorias de uso e ocupação da terra consideradas foram:

1. Agricultura;
2. Floresta Aberta;
3. Floresta Fechada;
4. Vegetação Herbácea;
5. Arbustos;
6. Urbano;
7. Vegetação Esparsa;
8. Corpos de Água.

Cada uma das imagens resultantes foi, então, escalonada para uma resolução espacial de 500 metros.

4.6 Adição das Bandas

Nesta etapa, todas as imagens normalizadas e de classificação de uso e ocupação da terra foram combinadas em uma única imagem multibanda utilizando a função '*addBands*' do *Google Earth Engine*. Essa técnica é comum em análises geoespaciais e de sensoriamento remoto, permitindo que um conjunto de variáveis sejam analisadas simultaneamente. Assim como as etapas anteriores, este procedimento foi automatizado no sistema WebGIS para que possa ser aplicada em outras regiões.

A imagem final consiste em 21 bandas, cada uma representando uma variável específica: Inclinação, Modelo de Elevação Digital (MDE), orientação do terreno, Temperatura máxima (Tmax), Temperatura mínima (Tmin), Precipitação acumulada (Ppt), Umidade do solo (URsoil), Velocidade do vento (Ws), Umidade do ar (UR), Índice de Vegetação por Diferença Normalizada (NDVI), Índice de Área Foliar (IAF), Agricultura, Floresta aberta, Floresta fechada, Vegetação herbácea, Arbustos, Urbano, Vegetação espaçada e Corpos de água (sendo que as últimas oito variáveis são derivadas do UOT), Distância euclidiana das estradas e Distância euclidiana das residências.

Cada banda da imagem final foi renomeada para corresponder ao nome da variável que representa, facilitando a interpretação e a manipulação dos dados nas etapas subsequentes da análise.

4.7 Construção e compilação do Modelo de *Deep Learning*

Todas as subetapas para construção e compilação do modelo de *Deep Learning* foram automatizadas durante a confecção do sistema WebGIS. O treinamento e a avaliação da precisão do modelo é uma das etapas cruciais. Para tanto é necessário um banco de dados com número homogêneo de amostras de cada classe a ser estimada. Os dados inseridos no arquivo contendo as amostras de fogo e não fogo mencionados no item 4.2 foram armazenados como um '*FeatureCollection*' chamado 'amostrasTreinamento1'.

Em seguida, os dados de treinamento, teste e validação foram preparados e exportados para uso em um modelo de aprendizado de máquina. Isso foi realizado pelas seguintes operações:

- Todos os nomes das bandas do conjunto de dados foram especificados e armazenados na variável '*featureNames*'.
- A variável '*trainingData*' foi criada, combinando os conjuntos de dados 'fogo'

e 'não-fogo' e adicionando uma nova coluna chamada 'random'. Esta coluna foi preenchida com números aleatórios e foi usada para dividir os dados em conjuntos de treinamento, teste e validação.

- O conjunto de dados foi dividido em três subconjuntos: 70% dos dados para treinamento, 20% para teste e 10% para validação.
- A função '*sampleRegions*' foi usada para amostrar os valores das bandas especificadas na vizinhança de cada pixel para cada subconjunto de dados. Essas amostras foram então exportadas como arquivos *TFRecord* para o *Google Cloud Storage*. Os arquivos *TFRecord* são um formato comum para armazenar grandes quantidades de dados multidimensionais (por exemplo, imagens, sequências) de maneira eficiente.
- Finalmente, as tarefas de exportação foram iniciadas para salvar os arquivos *TFRecord* no *Google Cloud Storage*.

Os conjuntos de treinamento, teste e validação foram usados, respectivamente, para treinar o modelo, avaliar seu desempenho durante o treinamento e verificar sua capacidade de generalizar para dados não vistos. As etapas mencionadas foram criadas no sistema WebGIS para que sejam executadas de forma automática.

Os dados de treinamento, teste e validação foram utilizados para desenvolver o modelo de aprendizado profundo com a biblioteca *TensorFlow*. A dimensão dos dados e o número de classes foram especificados. Neste caso, estamos lidando com um problema de classificação binária ($nClasses = 2$ – Fogo e Não Fogo).

Os parâmetros para o tamanho do lote (*batch size*) e o número de amostras usadas no processo de embaralhamento (*shuffle size*) foram definidos para alimentar os dados do modelo em lotes e garantir que os dados sejam embaralhados antes de cada época de treinamento.

Os arquivos *TFRecord* foram lidos como conjuntos de dados *TensorFlow*, permitindo uma leitura eficiente dos dados, sendo especialmente útil ao se lidar com grandes conjuntos de dados.

O modelo foi treinado utilizando técnicas de aprendizado supervisionado e seu objetivo principal foi prever a probabilidade de ocorrência de incêndios florestais com base nos fatores condicionantes. O modelo de aprendizado profundo foi definido usando a biblioteca *Keras*, que é uma interface de alto nível da biblioteca *TensorFlow*. A arquitetura do modelo é composta por várias camadas, cada uma com um propósito específico:

1. Camada de entrada: Esta é a primeira camada do modelo, onde os dados

são inseridos. A dimensão da entrada é determinada pelo tamanho dos dados de entrada.

2. Camada *Conv2D*: Esta é uma camada convolucional que realiza uma operação de convolução nos dados de entrada. A camada tem 64 filtros e a função de ativação *ReLU* (*Rectified Linear Unit*).
3. Camada *MaxPooling2D*: Esta camada realiza uma operação de *pooling* para reduzir a dimensionalidade espacial dos dados de entrada, o que ajuda a evitar o *overfitting*.
4. Camada *Dropout*: Esta camada descarta aleatoriamente uma fração (neste caso, 15%) dos neurônios durante o treinamento, o que também ajuda a evitar o *overfitting*.
5. Camadas *Dense*: Estas são as camadas completamente conectadas do modelo. A primeira camada *Dense* tem 128 neurônios e usa a função de ativação *ReLU*. A segunda camada *Dense* tem 16 neurônios e usa a função de ativação *ReLU*.
6. Camada de Saída: Esta é a última camada do modelo e usa uma função de ativação *softmax* para produzir as probabilidades da classe de saída. Como há duas classes (fogo e não fogo), a camada de saída tem 2 neurônios.

O modelo foi então compilado usando o otimizador Adam, que é um método de otimização estocástica, e a função de perda de entropia cruzada binária, que é adequada para problemas de classificação binária. Além disso, os parâmetros para acompanhar o treinamento foram definidos como:

Parada antecipada (*Early Stopping*): A parada antecipada é uma técnica usada para evitar o sobre ajuste (*overfitting*) durante o treinamento de um modelo de aprendizado de máquina. Neste caso, se a perda do modelo não diminuir após 10 épocas (definido pelo argumento *patience*), o treinamento será interrompido.

***Epochs*:** Este é o número de vezes que o modelo passará por todo o conjunto de dados de treinamento.

***Steps_per_epoch*:** Este é o número de lotes de amostras do conjunto de dados de treinamento a passar pelo modelo durante cada época. Neste caso, 100 lotes de amostras serão passados através do modelo para cada época.

***Validation_data*:** Este é o conjunto de dados usado para avaliar a perda e quaisquer métricas de modelo no final de cada época. Os dados de validação não são usados durante o treinamento do modelo.

Por fim, para estimar o risco de incêndio por meio do *deep learning*, múltiplos modelos foram construídos baseados em uma arquitetura de rede neural densamente conectada. Em cada modelo, o otimizador e a função de ativação foram variados conforme as combinações fornecidas: *Adam*, *Adelta* e *Adamax* como otimizadores e *relu*, *elu* e *LeakyReLU* como funções de ativação. Cada modelo foi treinado utilizando o conjunto de dados de treinamento, e o desempenho foi validado no conjunto de validação e teste. Ao final deste processo, o desempenho de cada combinação no conjunto de validação foi comparado, identificando o par otimizador/função de ativação que ofereceu os melhores resultados para a tarefa.

4.8 Avaliação do Modelo

Várias métricas foram usadas para avaliar o desempenho do modelo durante o treinamento, incluindo precisão, sensibilidade, verdadeiros positivos, verdadeiros negativos, falsos positivos, falsos negativos e recall.

Além disso, para avaliar a qualidade e precisão do modelo, outras métricas foram usadas, como AUC (*Area Under the ROC Curve*), Curva ROC e *Precision-Recall*. As métricas podem ser visualizadas na interface do sistema WebGIS após o treinamento do modelo.

AUC-ROC é uma métrica de desempenho que calcula a área sob a curva ROC (*Receiver Operating Characteristic*), que é um gráfico mostrando a taxa de verdadeiros positivos em função da taxa de falsos positivos em diferentes limiares de classificação. Uma AUC-ROC de 1,0 indica um modelo perfeito, enquanto uma AUC-ROC de 0,5 indica um modelo que não tem capacidade discriminatória.

Finalmente, o gráfico da curva ROC é exibido. Este gráfico permite visualizar o desempenho do modelo de classificação em todos os limiares de classificação, proporcionando uma maneira de selecionar o limiar que equilibra a sensibilidade e a especificidade de acordo com as necessidades da aplicação.

4.9 Identificação dos locais para alocação das equipes de combate

Esta etapa também foi automatizada no sistema WebGIS desenvolvido e visou a distribuição das equipes de combate de acordo com o risco de incêndio calculado previamente. Seja A o conjunto de todas as áreas, onde cada área α_i tem um risco de incêndio associado r_i e está localizada nas coordenadas (x_i, y_i) . O objetivo é agrupar

estas áreas em k *clusters* de forma que a soma dos riscos dentro de cada *cluster* seja maximizada e a distância entre as áreas e o centroide do *cluster* seja minimizada (Equação 7).

A função objetivo pode ser definida como:

$$\max = \sum_{j=1}^k \sum_{i=1}^n r_i X x_{ij} \quad \text{Equação 7}$$

Sujeito a:

- $\sum_{j=1}^k x_{ij} = 1$ para $i = 1, 2, \dots, n$ (cada área é atribuída a exatamente um *cluster*).
- x_{ij} é uma matriz binária, onde $x_{ij} = 1$ se a área i é atribuída ao cluster j , e 0 caso contrário.

A distância entre a área i e o centroide do *cluster* j é dado por (Equação 8):

$$d_{ij} = \sqrt{(x_i + c_{jx})^2 + (y_i + c_{jy})^2} \quad \text{Equação 8}$$

Onde $(c_{jx} + c_{jy})$ são as coordenadas do centroide j .

O algoritmo *K-means* utilizado na confecção do sistema WebGIS para escolha das áreas para alocação de equipe de combate a incêndios, levou em consideração tanto o risco de incêndio quanto a proximidade geográfica dos demais clusters. Este algoritmo possui uma sequência de 4 passos no seu processo de execução: (1) aleatorização dos centroides k ; (2) atribuição de cada área ao cluster cujo centroide está mais próximo, ponderando tanto a distância d_{ij} quanto o risco r_i ; (3) o centroide é recalculado utilizando a Equação 7 e a Equação 8; (4) o algoritmo refaz o passo 2 e 3 até que os clusters não mudem ou um número máximo de iterações seja alcançado.

Posteriormente, o centroide foi extraído e indicado como o local para instalação de infraestruturas de combate.

O centroide c_j de um cluster j foi calculado como (Equação 9 e Equação 10):

$$c_{jx} = \frac{\sum_{i=1}^n x_i X x_{ij}}{\sum_{i=1}^n x_{ij}} \quad \text{Equação 9}$$

$$c_{jy} = \frac{\sum_{i=1}^n y_i X x_{ij}}{\sum_{i=1}^n x_{ij}} \quad \text{Equação 10}$$

Após a execução do algoritmo *k-means* e da identificação dos centroides, esses pontos centrais podem ser usados como locais recomendados para estabelecer infraestruturas de combate a incêndios, como postos de bombeiros, depósitos de água ou bases para aeronaves de combate a incêndios. Posicionando estrategicamente esses recursos nos centroides, garante-se uma resposta mais rápida e eficaz às áreas

circundantes de alto risco dentro de cada cluster. Dessa forma, a abordagem não apenas identifica as áreas de maior risco, mas também fornece recomendações práticas sobre onde posicionar os recursos para combater eficazmente os incêndios nessas áreas.

Para avaliar a aplicabilidade prática desta tese, realizou-se uma comparação entre as posições reais das estruturas destinadas ao combate de incêndios florestais (equipadas com aeronaves de combate) na região de Andaluzia e aquelas sugeridas pelo método proposto. A partir disso, confeccionou-se um mapa destacando ambas as coordenadas. Para isso, os parâmetros utilizados foram 31 clusters e o valor de risco de incêndio acima de 0,75. O sistema WebGIS permite que estes parâmetros sejam alterados.

Podemos visualizar todas as variáveis utilizadas para confecção do modelo na Figura 12.




Figura 12 - Variáveis utilizadas para confecção do modelo de Deep learning de estimativa de incêndios florestais.

4.10 Transferência de aprendizado em modelos de previsão de risco de incêndio: uma análise comparativa entre Brasil, Austrália e o continente Africano

A previsão de riscos de incêndio desempenha um papel crucial na gestão e prevenção de desastres naturais. Com o avanço das técnicas de *deep learning*, a capacidade de desenvolver modelos de previsão mais precisos e robustos tornou-se uma realidade. No entanto, a aplicabilidade e eficácia desses modelos em diferentes

regiões geográficas ainda são áreas de investigação incipiente. Neste contexto, este estudo explora a transferência de aprendizado de um modelo de *deep learning* inicialmente treinado no Brasil para prever riscos de incêndio e sua subsequente aplicação na Austrália e no continente africano.

Com o objetivo de aplicar a metodologia proposta nesta tese em uma região diferente, foi desenvolvido um modelo de aprendizado profundo para estimar o risco de incêndios no Brasil. As variáveis selecionadas foram consistentes com as previamente descritas, excluindo-se, no entanto, os fatores antrópicos (distância euclidiana das estradas e distância euclidiana das residências). A fim de avaliar a capacidade de generalização do modelo, sua aplicação foi estendida a regiões como o continente Africano e a Austrália. A escolha destas regiões deve-se à sua frequente vulnerabilidade a incêndios florestais, com destaque para a intensa temporada de 2019/2020.

Os dados relativos às áreas queimadas foram adquiridos do conjunto ESA/CCI/FireCCI/5_1, referente ao ano de 2020. Esta base de dados possui uma banda denominada 'BurnDate', que indica a data de ocorrência de um incêndio. A partir destas informações, foram gerados pontos representativos das áreas queimadas, rotulados com o valor 1, simbolizando a presença de fogo.

Adicionalmente, para gerar amostras aleatórias de não fogo, foram coletados dados de cobertura do solo do conjunto ESA/WorldCover/v100. Estes dados foram filtrados para identificar áreas com baixa probabilidade de ocorrência de incêndio, como zonas de solo exposto, corpos d'água e áreas urbanizadas. Estas regiões foram então convertidas em pontos e rotuladas com o valor 0, indicando ausência de fogo.

Combinamos os pontos representativos de áreas queimadas e não queimadas, formando um conjunto de treinamento balanceado. No caso do Brasil, identificamos 16 mil pontos de queimadas, resultando em um total de 32 mil amostras, considerando ambas as categorias. Esse conjunto foi então dividido para treinamento, validação e teste. Após o treinamento, o desempenho do modelo foi avaliado com as métricas de desempenho mencionadas anteriormente. Por fim, para confirmar a versatilidade do modelo, foi aplicado no continente Africano e na Austrália para estimar o risco de incêndio. É importante ressaltar que, o modelo foi treinado utilizando amostras de incêndios florestais e variáveis de entrada específicas para o Brasil. Portanto, sua aplicação tanto no continente Africano quanto na Austrália baseou-se em conjuntos de dados completamente distintos do utilizado no treinamento. Os resultados podem ser consultados no apêndice.

Para o treinamento do modelo de *deep learning* na previsão do risco de incêndios florestais, é preciso definir as variáveis condicionantes à ocorrência, a área onde será feita a previsão, as amostras para o treinamento e a importação dos fatores externos ao *Google Earth Engine* (Figura 13 e 14).




Figura 13 - Interface para inserção da área de estudo e das amostras para o treinamento de *deep learning*.




Figura 14 - Interface para inserção da área de estudo e das amostras para o treinamento de *deep learning*.

A maioria dos fatores associados ao risco de ocorrência de incêndios florestais já se encontra no banco de dados do *Google Earth Engine* (Figuras 15, 16 e 17). A área de previsão, a distância de estradas, a distância de residências e as amostras de treinamento podem ser importadas do ambiente local do computador. Alternativamente, elas podem ser inseridas no *Asset* do *Google Earth Engine* e, posteriormente, importadas por meio dessa funcionalidade.




Figura 15 - Adicionando fatores relacionados a topografia.




Figura 16 - Adicionando fatores meteorológicos.




Figura 17 - Adicionando fatores relacionados a vegetação.

Após a escolha dos fatores condicionantes a ocorrência de incêndios florestais serem extraídos com as amostras de treinamento, o próximo passo é verificar se já foram enviados para o *google cloud storage*. Isso é feito com o símbolo . Agora o próximo passo é treinar o modelo de previsão de risco de incêndios, essa etapa é demonstrada com o símbolo da rede neural .

5 RESULTADOS E DISCUSSÃO

A Figura 18 apresenta a correlação entre os fatores condicionantes à ocorrência de incêndios florestais usados para treinar o modelo de aprendizagem de máquinas.




Figura 18 - Correlação entre os fatores utilizados para treinar o modelo em Andaluzia.

De acordo com a Figura 18, o IAF e o NDVI apresentam forte correlação positiva ($r = 0,75$), indicando que áreas com vegetação mais densa tendem a ter uma vegetação mais verde e saudável. Isso pode ter implicações para o risco de incêndio, pois áreas com vegetação mais densa fornecem mais combustível, aumentando a gravidade de ocorrência de incêndios florestais.

Por outro lado, o NDVI apresentou correlação positiva moderada ($r = 0,31$) com a umidade do solo, ou seja, áreas com vegetação mais saudável e densa tendem a ter solos mais úmidos. A vegetação densa e saudável é responsável por auxiliar o aumento de umidade local, tornando a área menos propensa à ocorrência de incêndios florestais.

Como já era esperado, a umidade do solo e a precipitação apresentaram forte correlação positiva ($r = 0,67$). Isso pode indicar um período de baixo risco de incêndio,

pois a umidade elevada do solo e a precipitação reduzem a secura dos materiais combustíveis.

A temperatura mínima é mais fortemente influenciada pela elevação, representada na Figura 18 pelo MDE, ($r = -0,91$) do que a temperatura máxima ($r = -0,47$). As implicações dessa observação no contexto dos incêndios florestais são interessantes. É bem estabelecido que as temperaturas mais frias são geralmente menos favoráveis para a propagação de incêndios florestais. Isso sugere que, áreas de maior altitude (elevação) podem ser consideradas menos propensas a incêndios florestais.

Áreas de maior altitude, maior MDE, também tendem a ter terrenos mais íngremes ($r = 0,58$). Este é um ponto a considerar, uma vez que a inclinação pode influenciar a velocidade e a direção da propagação do fogo.

A temperatura máxima e a umidade relativa apresentam correlação negativa moderada ($r = -0,57$). Condições de alta temperatura estão associadas à baixa umidade relativa. Ambos são fatores críticos que influenciam o risco de incêndio, com altas temperaturas e baixa umidade aumentando a probabilidade de ocorrência de incêndio florestal (SOARES, R. V.; BATISTA; TETTO, 2017).

A face de exposição ao sol, representada pela orientação do terreno (Figura 19a), pode influenciar a quantidade de luz solar direta que ela recebe. Dependendo da orientação geográfica, algumas áreas podem receber mais luz solar durante determinadas horas do dia ou estações do ano. A luz solar intensa e direta pode aumentar a temperatura do solo e das plantas, resultando em condições mais secas e inflamáveis. Isso pode facilitar a propagação do fogo, caso haja uma fonte de ignição.

Além disso, a secura do material combustível desempenha um papel importante na propagação e na intensidade dos incêndios. Em regiões com maior incidência solar, combinada com baixa umidade e escassez de chuvas, o material vegetal, como a vegetação rasteira, gramíneas, arbustos e florestas, tende a ficar mais seco e inflamável. Essas condições tornam o terreno propício para a propagação rápida e intensa do fogo, aumentando o risco de incêndios.

No gráfico apresentado na Figura 19b, é possível observar que a classe de uso e ocupação da terra referente a floresta aberta tem a maior frequência de ocorrências de incêndios (844), seguida por arbustos (452) e agricultura (333). Essas três categorias, em conjunto, representam uma parcela significativa de 77,17% de todas as ocorrências de incêndios florestais em Andaluzia.




Figura 19 - Frequência de ocorrência de incêndio de acordo com o (a) orientação do terreno e com o (b) uso e ocupação da terra.

A presença de vegetação densa e arbustiva pode criar uma fonte significativa de material combustível, tornando essas áreas mais suscetíveis à ocorrência de incêndios. Além disso, a vegetação densa pode aumentar a propagação do fogo e tornar o controle mais difícil. Outra questão importante é, mesmo que a vegetação herbácea seja menos densa do que florestas abertas ou arbustos, ela pode secar rapidamente e servir como combustível fino para incêndios.

A quantidade de material combustível define se o fogo vai ou não se propagar, seu comportamento e a intensidade de calor liberada pelo processo de combustão. O arranjo e continuidade desse material são fatores determinantes para a quantidade de oxigênio disponível para queima. Esses fatores quando somados às estações severas de fogo, aumentam a extensão, a severidade e a frequência dos incêndios florestais (WESTERLING, 2016).

Segundo Soares e colaboradores (2017) a própria transpiração da floresta aumenta a umidade relativa do ar diminuindo assim o risco de incêndio, bem como sua propagação ficaria bastante dificultada. Por outro lado, uma floresta aberta faria justamente o contrário, pois permitiria a livre passagem da radiação solar e das correntes de ar, produzindo aumento na temperatura da vegetação, facilitando a propagação de um incêndio florestal (HELBINGEN JÚNIOR, 2017).

Embora a categoria de agricultura também apresente uma frequência considerável de incêndios florestais, é importante investigar mais profundamente os tipos específicos de práticas agrícolas e suas possíveis contribuições para a ocorrência de incêndios.

A variabilidade de diferentes fatores em relação à ocorrência de incêndios

florestais é mostrada na Figura 20. A análise dos dados para o Modelo Digital de Elevação (Figura 20a) mostrou que a maioria dos incêndios (33,93%) ocorreu em áreas com altitude de até 161,5 metros. Além disso, conforme a elevação aumenta, a frequência de incêndios tende a diminuir gradualmente, com uma ocorrência de apenas 2,03% em áreas com elevação entre 1.322,5 e 2.043,0 metros. Em áreas de menor elevação é comum encontrar uma maior densidade de vegetação e maior disponibilidade de combustível vegetal, o que pode favorecer a propagação do fogo. Além disso, essas áreas costumam ter maior presença de atividades humanas, aumentando a probabilidade de ocorrência dos incêndios.

Diferentes intervalos de inclinação (Figura 20b) apresentaram proporções distintas de ocorrência de incêndios florestais. A maioria dos incêndios (27,84%) ocorreu em áreas com inclinação entre 0° e $1,31^{\circ}$. Conforme a inclinação aumenta, a frequência de incêndios tende a diminuir gradualmente, com uma ocorrência de 2,08% em áreas com inclinação entre $16,08^{\circ}$ e $24,76^{\circ}$. Cabe ressaltar que, o incêndio florestal se propaga com maior velocidade em terrenos mais inclinados, uma vez que a chama se aproxima mais do material combustível a sua frente.

A atividade do fogo na região de Andaluzia concentra-se principalmente em áreas com temperatura máxima do ar ambiente com média anual superior a 28°C (Figura 20c), enquanto as ocorrências são cerca de 80% menores em temperaturas mais baixas (Figura 20d).

A umidade relativa é um indicador em porcentagem da saturação do ar a determinada temperatura e afeta diretamente o conteúdo de umidade do material combustível. Devido as propriedades higroscópicas do material combustível, existe uma troca contínua de vapor d'água com o ambiente, desde que não haja influência da precipitação. A umidade relativa do ar rege esse processo de perda e ganho de água (SANTOS, 2020).

Segundo White, Ribeiro e Souza (2013) a intensidade de um incêndio também está ligada às condições de umidade relativa, tornando-se uma variável de entrada importante para modelos de comportamento do fogo.

A umidade relativa é uma medida crucial para avaliar as condições climáticas e o risco de incêndios florestais (Figura 20f). Através dessa análise, é possível identificar padrões e entender como a umidade relativa pode influenciar a ocorrência desses eventos. Foi notado que o intervalo entre 61,04 e 65,32% de umidade têm as maiores frequências absolutas, totalizando 46,55% do total de ocorrências de incêndios florestais. À medida que a umidade relativa aumenta, a frequência de

ocorrências diminuí, mostrando que condições com maior umidade relativa estão menos propensas à ocorrência de incêndios florestais (acima de 70% de umidade aconteceram 15% das ocorrências), pois dificultam a ignição e a propagação do fogo.

Considerando que a velocidade do vento na área de estudo variou de 2,90 a 4,22 m/s, nota-se uma maior concentração de ocorrência de incêndios entre 2,40 e 3,0 m/s (Figura 20g), o que implica que a velocidade do vento acelera a atividade de incêndios florestais.




Figura 20 - Frequência de ocorrência de incêndios com relação aos fatores analisados.

O Índice de Área Foliar (IAF) está diretamente relacionado à biomassa vegetal e à disponibilidade de combustível para a propagação de incêndios florestais (Figura

20j). Para a região de Andaluzia, a maioria dos incêndios (26,33%) ocorreu em áreas com IAF entre 4,29 e 5,97 e com uma ocorrência de apenas 0,05% em áreas com IAF entre 14,92 e 25,50. Em áreas com IAF elevado, espera-se que haja uma maior quantidade de material vegetal disponível para ser queimado, o que pode aumentar a intensidade e a propagação dos incêndios. Por outro lado, áreas com menor IAF podem ter menos material vegetal para sustentar a propagação do fogo, o que explicaria a diminuição da frequência de incêndios nos intervalos de IAF mais baixos (16 %).

A atividade do fogo na área de estudo mostra uma tendência de diminuição gradual com o aumento da distância da estrada, e a maioria dos incêndios florestais ocorreu a uma distância inferior a 2.000 m da estrada mais próxima (Figura 20k), indicando como as atividades humanas ao longo das redes rodoviárias influenciam positivamente a ocorrência de incêndios na região.

Com relação a distância de residências e os locais de ocorrência dos incêndios florestais (Figura 20l), cerca de 90 % dos casos acontecem com distâncias de até 5.000 metros e a frequência vai reduzindo à medida que a distância das residências aumenta. Por exemplo, as áreas mais distantes das residências (>10.000 m) não são caracterizadas por ocorrência de incêndios florestais.

Na Tabela 2 é apresentado os resultados das diferentes combinações de algoritmos de otimização (*Adam*, *Adelta*, *Adamax*) e funções de ativação (*Relu*, *Elu*, *LeakyReLU*) testadas para estimar o risco de incêndios florestais. As combinações que usaram o algoritmo de otimização *Adam* e a função de ativação *LeakyReLU* forneceram os melhores resultados em termos de acurácia no conjunto de treinamento (0,8580). No entanto, quando considerado a validação, a melhor acurácia foi alcançada com *Adam* + *Elu* (0,8410) e *Adamax* + *Elu/LeakyReLU* (ambos 0,8361). *Adelta* parece ser o algoritmo de otimização menos eficaz para esta tarefa, conforme demonstrado por suas menores pontuações de acurácia, tanto em treinamento quanto em validação.

Tabela 2 - Estatísticas de treinamento e validação da *deep learning* utilizada para prever incêndios florestais.

Treinamento								
CNN	Algoritmo	Função ativação	Acurácia	Sensibilidade	TrueP	FalseP	RECALL	AUC
1	Adam	Relu	0,8270	0,9790	827	173	0,8270	0,9670
2	Adam	Elu	0,8310	0,9790	831	169	0,8310	0,9660
3	Adam	LeakyReLU	0,8580	0,9980	858	142	0,8580	0,9630
4	Adelta	Relu	0,1970	0,1030	197	803	0,1970	0,7760
5	Adelta	Elu	0,7470	0,8550	747	253	0,7470	0,8380
6	Adelta	LeakyReLU	0,5080	0,4860	508	492	0,5080	0,7220
7	Adamax	Relu	0,8210	0,9840	821	179	0,8210	0,9640
8	Adamax	Elu	0,8230	0,9720	823	177	0,8230	0,9370
9	Adamax	LeakyReLU	0,8180	0,9720	818	182	0,8180	0,9620
Validação								
CNN	Algoritmo	Função ativação	Acurácia	Sensibilidade	TrueP	FalseP	RECALL	AUC
1	Adam	Relu	0,8169	0,9735	678	152	0,8169	0,9040
2	Adam	Elu	0,8410	0,9687	698	132	0,8410	0,9130
3	Adam	LeakyReLU	0,8024	0,9711	666	164	0,8024	0,8980
4	Adelta	Relu	0,5373	0,5783	446	384	0,5373	0,7460
5	Adelta	Elu	0,7253	0,8217	602	228	0,7253	0,7420
6	Adelta	LeakyReLU	0,6988	0,7831	580	250	0,6988	0,7220
7	Adamax	Relu	0,8217	0,9687	682	148	0,8217	0,9060
8	Adamax	Elu	0,8361	0,9663	694	136	0,8361	0,9090
9	Adamax	LeakyReLU	0,8361	0,9735	694	136	0,8361	0,9140

Em termos de sensibilidade (também conhecida como taxa de verdadeiros positivos), o par *Adam* + *LeakyReLU* no conjunto de treinamento e *Adamax* + *LeakyReLU* no conjunto de validação obteve os melhores resultados. No conjunto de treinamento, as melhores AUCs foram alcançadas por *Adam* + *Relu* e *Adam* + *Elu*, enquanto na validação, a melhor AUC foi alcançada por *Adam* + *Elu*.

A função de ativação parece ter um impacto no desempenho do modelo. Em particular, a função de ativação *LeakyReLU* parece ter um desempenho melhor com o algoritmo *Adam*, enquanto a função de ativação *ReLU* parece ter um desempenho melhor com o algoritmo *Adamax*.

No conjunto de teste, os modelos que usam o algoritmo *Adam* ou *Adamax* e a função de ativação *ReLU* ou *elu* tendem a ter o melhor desempenho, com acurácias acima de 80% e AUCs próximas a 0,9. Isso sugere que essas configurações podem ser as mais eficazes para a tarefa de classificação do risco de incêndio.

A sensibilidade à especificidade é uma medida de quão bem o modelo identifica verdadeiros positivos enquanto mantém uma taxa de falsos positivos baixa. Os modelos que usam o algoritmo *Adam* ou *Adamax* e a função de ativação *relu* ou *elu* tendem a ter os valores mais altos para essa métrica, sugerindo que eles são eficazes em identificar áreas de alto risco de incêndio sem marcar muitas áreas de baixo risco como de alto risco.

O recall é uma medida de quão bem o modelo identifica verdadeiros positivos. Os modelos que usam o algoritmo *Adam* ou *Adamax* e a função de ativação *relu* ou *elu* também tendem a ter os valores mais altos para essa métrica, sugerindo que eles são eficazes em identificar áreas de alto risco de incêndio.

A Figura 21 exibe as estatísticas do treinamento para diversas combinações de algoritmos e funções de ativação nas camadas ocultas. Observa-se uma maior estabilidade no treinamento com as configurações que empregaram os algoritmos *Adam* e *Adamx*. Até a 40ª época de treinamento, as diferentes funções de ativação apresentaram comportamentos similares. No entanto, após essa marca, as funções *LeakyRelu* e *Relu* começaram a apresentar erros em todos os algoritmos.

A combinação de Adam com a função de ativação *Elu* demonstrou ser a mais estável durante o treinamento, conforme ilustrado na Figura 21. Enquanto outras configurações apresentaram variações, essa combinação se destacou por sua consistência.




Figura 21 - Acurácia do treinamento e validação dos modelos de deep learning utilizados para predição de risco de incêndios florestais.

A estabilidade durante o treinamento é crucial, pois garante que o modelo não sofra de problemas como o *overfitting* (quando o modelo se ajusta demais aos dados de treinamento e tem um desempenho ruim em dados novos). Isso é importante porque indica que o modelo é confiável e não é propenso a variações drásticas no desempenho à medida que novos dados são apresentados.

Na Figura 22 são mostradas as curvas ROC correspondentes a diversas combinações de algoritmos e funções de ativação, utilizadas para avaliar o desempenho dos modelos na classificação de risco de incêndios.




Figura 22 - AUC e curva ROC para analisar a acurácia dos modelos de deep learning utilizados para prever o risco de incêndios.

A escolha de algoritmo de treinamento e função de ativação desempenha um papel crucial para classificação do risco de incêndios florestais. O algoritmo *Adam*, em particular, mostrou-se promissor, especialmente quando combinado com as funções de ativação *relu* e *elu*. Por outro lado, o desempenho inferior do *Adelta* sugere a necessidade de mais investigações ou a consideração de alternativas. O *Adamax*, com sua performance variável, destaca a importância de experimentações contínuas e ajustes refinados para alcançar a melhor configuração.

O algoritmo *Adam* mostrou-se consistentemente em todas as fases, independentemente da função de ativação escolhida. Especificamente, a função *relu* apresentou uma ligeira vantagem durante a fase de treinamento, sugerindo que essa combinação pode ser particularmente eficaz para capturar padrões nos dados. No entanto, na fase de validação, a função *elu* superou as outras, indicando sua robustez em dados não vistos anteriormente quando combinada com o *Adam*. Esta observação é reforçada pelos resultados da fase de teste, onde a *elu* novamente se destacou.

Por outro lado, o algoritmo *Adelta* apresentou um desempenho notavelmente inferior em todas as fases. Mesmo com a função *elu*, que tendeu a ter a melhor performance com este algoritmo, os valores de AUC foram consistentemente mais baixos em comparação com as outras combinações. Isso sugere que o *Adelta* pode não ser o algoritmo mais adequado para este conjunto de dados, ou pode exigir um ajuste de hiperparâmetros mais refinado.

O *Adamax* apresentou um desempenho variável. Durante o treinamento, as

funções *relu* e *LeakyReLU* tiveram desempenhos semelhantes e superiores à *elu*. No entanto, na fase de validação, a *LeakyReLU* mostrou-se ligeiramente superior, enquanto na fase de teste, as três funções de ativação apresentaram desempenhos muito próximos.

Figura 23 exibe um mapa de risco de incêndios para a região da Andaluzia, gerado pela combinação do algoritmo *Adam* com a função de ativação *relu*. As cores no mapa variam de verde a vermelho para representar o grau de risco. O verde, correspondendo a um valor de risco tendendo a 0, indica baixo risco, enquanto o vermelho, correspondendo a um valor tendendo a 1, sinaliza alto risco. Pontos pretos dispersos pelo mapa marcam os focos registrados de incêndios. Notavelmente, a maioria desses focos está concentrada nas áreas vermelhas, ou zonas de alto risco. Isso evidencia a eficácia do modelo em identificar e destacar regiões com características propensas a incêndios, reforçando sua relevância para estratégias de prevenção e gestão de riscos na região.




Figura 23 - Mapa de risco de incêndios para Andaluzia.

Com o objetivo de avaliar a eficácia do método proposto no estudo, foi desenvolvido um mapa que permite a visualização e comparação entre a localização real das infraestruturas de combate a incêndios e as posições indicadas pelo modelo de agrupamento e mapa de risco (Figura 24).



Figura 24 - Comparação entre localizações das infraestruturas de combate (bases) e os centroides dos clusters formados

O modelo proposto nessa tese pode ser usado para indicar locais recomendados à instalação de infraestruturas de combate a incêndios, como postos de bombeiros, depósitos de água ou bases para aeronaves de combate a incêndios.

A região de Andaluzia dispõe de 31 aeronaves dedicadas ao combate de incêndios florestais. Foi analisada a localização atual onde estas aeronaves estão estacionadas em comparação à posição dos centroides sugeridos pelo modelo. Para tal, a região foi segmentada em 31 clusters, correspondendo ao número de aeronaves, facilitando assim a comparação com o método proposto.

Adicionalmente, após uma série de testes com o modelo de agrupamento, estabeleceu-se um valor de risco de incêndio superior a 0,75 como critério de filtragem. Esse valor foi determinado com base em sua eficácia em identificar áreas de maior prioridade para a alocação de recursos.

Em Andaluzia, o método de alocação de infraestrutura foi inicialmente estabelecido sem considerar fatores estritamente técnicos. A proximidade de áreas florestais desempenhou um papel crucial, provavelmente para assegurar uma resposta ágil a possíveis incêndios. Além disso, houve uma preferência por terrenos

já pertencentes ao governo ou a entidades que não exigiriam pagamento, evitando assim custos adicionais com a compra de propriedades. Uma preocupação evidente foi a distribuição equitativa da infraestrutura entre todas as províncias de Andaluzia, garantindo uma cobertura abrangente. Posteriormente, algumas regiões, como Navalcavallo, foram incorporadas devido ao risco elevado e ao tempo de resposta necessário em caso de incêndios. No entanto, é importante destacar que todas essas decisões foram tomadas sem a orientação de um estudo técnico formal ou detalhado.

A observação anterior pode elucidar as razões pelas quais existem discrepâncias entre as localizações reais das aeronaves e as posições indicadas pelo método proposto nesta tese. Para alinhar ainda mais esses resultados, pesquisas futuras poderiam incorporar restrições ou condições adicionais. Poderiam ser considerados fatores como a distância máxima permitida entre as instalações, os custos associados à configuração das infraestruturas e a presença de barreiras físicas. Essas considerações de restrições adicionais podem aprimorar ainda mais o modelo, tornando-o mais robusto e adaptável a diferentes cenários e desafios.

5.1 Transferência de aprendizado em modelos de previsão de risco de incêndio: uma análise comparativa entre Brasil, Austrália e o continente Africano

Após a conclusão do treinamento, uma série de estatísticas é gerada para que o usuário possa verificar o desempenho do modelo e fazer ajustes, caso seja necessário (Figura 25). Esses ajustes podem ser realizados alterando o tipo de função de ativação, o algoritmo de treinamento, o número de camadas, o número de neurônios em cada camada ou até mesmo os fatores de risco de incêndio.




Figura 25 - Interface para treinamento e exibição do desempenho do modelo por meio de gráficos e estatísticas.

Com a conclusão da etapa de treinamento, o modelo selecionado foi salvo na plataforma *Google Cloud*, utilizando o serviço *AI Platform*. Dessa forma, o modelo pode ser aplicado a qualquer região que possua as informações condicionantes para a ocorrência do risco de incêndios. Neste exemplo, é demonstrado para o Brasil (Figura 26).




Figura 26 - Tela para visualização do mapa de risco gerado pelo modelo de *deep learning*.

Com o mapa de risco de incêndio florestal estimado pela *deep learning*, o passo seguinte é agrupar os pontos de maior risco de incêndios e gerar um centroide para cada grupo (Figura 27). O centroide será o ponto mais próximo de cada ponto de risco de incêndio florestal, ou seja, o ponto em que a distância do centro do cluster para todos os pontos de risco de incêndio é mínima. Dessa forma, esse centro também

pode ser considerado uma boa localização para a instalação de infraestruturas de combate a incêndios florestais.




Figura 27 - Exibição e cálculo do número de clusters.

Os resultados preliminares indicam uma transferência bem-sucedida do aprendizado (Figuras 28, 29 e 30). Uma possível explicação para essa transferência eficaz pode ser a relevância e disponibilidade de características universais, como temperatura, umidade e velocidade do vento, em todas as três regiões. Além disso, a robustez do modelo treinado inicialmente no Brasil sugere que ele possui uma capacidade intrínseca de generalizar para uma variedade de condições, tornando-o apto para aplicação em diferentes contextos geográficos.




Figura 28 - Mapa de risco de incêndio florestal para o Brasil.




Figura 29 - Mapa de risco de incêndio para o continente Africano.




Figura 30 - Mapa de risco de incêndio florestal para a Austrália.

Outro fator que pode ter contribuído para a transferência bem-sucedida é a presença de biomas semelhantes em todas as três regiões, como savanas e florestas tropicais. Essa similaridade nos biomas pode indicar condições semelhantes que influenciam os incêndios, permitindo uma transferência de aprendizado mais fluida. A qualidade e abrangência do conjunto de dados original do Brasil também podem ter desempenhado um papel crucial, permitindo ao modelo aprender características fundamentais dos incêndios que são generalizáveis a outras regiões.

A complexidade inerente das redes neurais profundas, com sua capacidade de aprender representações hierárquicas dos dados, pode ter sido um fator determinante na captura de padrões relevantes em diferentes contextos geográficos. Embora o modelo não tenha sido re-treinado para as novas regiões, a possibilidade de ajuste fino usando dados locais em estudos futuros pode oferecer uma oportunidade para otimizar ainda mais seu desempenho.

Em conclusão, os resultados deste estudo sugerem que a transferência de aprendizado é uma abordagem viável para modelos de previsão de risco de incêndio entre diferentes regiões geográficas. No entanto, é essencial continuar monitorando e validando o desempenho do modelo em diferentes condições e ao longo do tempo para garantir sua precisão e robustez contínuas.

6 CONCLUSÃO

Ao longo deste estudo, foram alcançados resultados significativos em diversas frentes essenciais para o combate a incêndios florestais. Primeiramente, foi possível gerar mapas de risco de incêndios florestais, levando em consideração tanto os fatores de ignição quanto de propagação. Além disso, os parâmetros das técnicas de aprendizado de máquina foram calibrados e validados com sucesso para a previsão de risco de incêndios florestais.

No que diz respeito à gestão e alocação de recursos, desenvolveu-se um método eficaz para agrupar áreas de alto risco de incêndio, indicando os locais mais adequados para a instalação de infraestruturas de combate. Este processo foi ainda mais otimizado com a automação da criação de banco de dados, treinamento e avaliação do modelo de aprendizado de máquina, bem como o agrupamento e indicação de locais para infraestrutura de combate a incêndios.

Finalmente, para garantir que o sistema proposto seja acessível e de fácil utilização, foi desenvolvida uma interface de usuário intuitiva, permitindo que os profissionais da área possam aplicar e beneficiar-se das ferramentas e métodos propostos de maneira eficiente.

7 REFERÊNCIAS

- ADAB, H.; KANNIAH, K. D.; SOLAIMANI, K. Modeling forest fire risk in the northeast of Iran using remote sensing and GIS techniques. **Natural Hazards**, v. 65, n. 3, p. 1723–1743, 17 jan. 2013.
- ARGAÑARAZ, J. P. et al. Human and biophysical drivers of fires in Semiarid Chaco mountains of Central Argentina. **Science of the Total Environment**, v. 520, p. 1–12, 1 jul. 2015.
- ARPACI, A. et al. Using multi variate data mining techniques for estimating fire susceptibility of Tyrolean forests. **Applied Geography**, v. 53, p. 258–270, 1 set. 2014.
- ATABEKOVA, A.; BELOUSOV, A.; SHOUSTIKOVA, T. Web 3.0-Based Non-formal Learning to Meet the Third Millennium Education Requirements: University Students' Perceptions. **Procedia - Social and Behavioral Sciences**, v. 214, p. 511–519, dez. 2015.
- BAKER, T. R. WebGIS in Education. [S.l: s.n.], 2015. p. 105–115.
- BAR MASSADA, A. et al. Wildfire ignition-distribution modelling: a comparative study in the Huron–Manistee National Forest, Michigan, USA. **International Journal of Wildland Fire**, v. 22, n. 2, p. 174, 15 abr. 2013. Disponível em: <<http://www.publish.csiro.au/?paper=WF11178>>. Acesso em: 26 mar. 2020.
- BARBALHO, V. M. de S. **Sistemas Baseados em Conhecimento e Lógica Difusa para Simulação do Processo Chuva-Vazão**. 2001. 86 f. Universidade Federal do Rio de Janeiro, 2001.
- BARNES, S. F.; GOLAKOFF, I.; BARNES, K. **The Fire Triangle**. Disponível em: <<https://interwork.sdsu.edu/fire/resources/fire-burns.htm>>. Acesso em: 5 maio 2020.
- BEUTLING, A. et al. Quantidade de material combustível superficial em reflorestamentos de Araucaria angustifolia (Bert.) O. Ktze. **FLORESTA**, v. 35, n. 3, p. 465–472, 2005.
- BOOKBINDER, J. H.; MARTELL, D. L. TIME-DEPENDENT QUEUEING APPROACH TO HELICOPTER ALLOCATION FOR FOREST FIRE INITIAL-ATTACK. **INFOR Journal**, v. 17, n. 1, p. 58–70, 1979.

BRAGA, A. de P. **Redes Neurais Artificiais. Teoria e Aplicações**. Rio de Janeiro: Editora LTC, 2007.

BRAGA, A.; FERREIRA, A. C. P.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. [S.l.]: LTC Editora Rio de Janeiro, Brazil, 2007.

CHMIELEWSKI, S. et al. Citizen science and WebGIS for outdoor advertisement visual pollution assessment. **Computers, Environment and Urban Systems**, v. 67, p. 97–109, jan. 2018.

CHUVIECO, E. et al. Combining NDVI and surface temperature for the estimation of live fuel moisture content in forest fire danger rating. 30 ago. 2004, [S.l.]: Elsevier Inc., 30 ago. 2004. p. 322–331.

_____. Development of a framework for fire risk assessment using remote sensing and geographic information system technologies. **Ecological Modelling**, v. 221, n. 1, p. 46–58, 10 jan. 2010.

_____. Fuel Loads and Fuel Type Mapping. [S.l: s.n.], 2003. p. 119–142. Disponível em: <http://www.worldscientific.com/doi/abs/10.1142/9789812791177_0005>.

CHUVIECO, E.; CONGALTON, R. G. Application of remote sensing and geographic information systems to forest fire hazard mapping. **Remote Sensing of Environment**, v. 29, n. 2, p. 147–159, 1 ago. 1989.

CHUVIECO, E.; KASISCHKE, E. S. Remote sensing information for fire management and fire effects assessment. **Journal of Geophysical Research**, v. 112, n. G1, p. G01S90, 19 jan. 2007. Disponível em: <<http://doi.wiley.com/10.1029/2006JG000230>>. Acesso em: 31 mar. 2020.

CORREIA, F. J. M. **O contributo dos serviços de ecossistemas na prevenção e resiliência a incêndios rurais no rede Natura 2000, no município de Arouca**. 2017. 131 f. Dissertação (Mestrado em Riscos, Cidades e Ordenamento do Território) - Universidade do Porto, 2017.

COSTAFREDA-AUMEDES, S.; COMAS, C.; VEGA-GARCIA, C. Human-caused fire occurrence modelling in perspective: a review. **International Journal of Wildland Fire**, v. 26, n. 12, p. 983, 2017. Disponível em: <<http://www.publish.csiro.au/?paper=WF17026>>.

COTTER, J. **Forest Fires: influences of climate change and human activity**. . Exeter, UK: Greenpeace Research Laboratories Technical. Disponível em: <http://www.greenpeace.to/publications/Climate_Change_and_Forest_Fires_2009.pdf>. , 2009

ERLE, S.; GIBSON, R.; WALSH, J. **Mapping Hacks: Tips & Tools for Electronic Cartography**. 1. ed. Sebastopol, CA: O'Reilly Media, Inc., 2005.

ESKANDARI, S.; CHUVIECO, E. Fire danger assessment in Iran based on geospatial information. **International Journal of Applied Earth Observation and Geoinformation**, v. 42, p. 57–64, 1 out. 2015.

EUGENIO, F. C. et al. GIS applied to location of fires detection towers in domain area of tropical forest. **Science of the Total Environment**, v. 562, p. 542–549, 15 ago. 2016.

FERNÁNDEZ, S. M.; FALERO, E. M.; PÉREZ-GONZÁLEZ, J. M. Optimization of the resources management in fighting wildfires. **Environmental Management**, v. 30, n. 3, p. 352–364, 1 set. 2002. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/12148070>>. Acesso em: 27 mar. 2020.

FIEDLER, N. C.; SANT'ANNA, C. M.; RAMALHO, A. H. C. **Incêndios Florestais**. 1. ed. Jerônimo Monteiro: Visconde do Rio Branco: Suprema, 2020.

GARCÍA, M. et al. A Live Fuel Moisture Content Product from Landsat TM Satellite Time Series for Implementation in Fire Behavior Models. **Remote Sensing**, v. 12, n. 11, p. 1714, 27 maio 2020. Disponível em: <<https://www.mdpi.com/2072-4292/12/11/1714>>.

GHORBANZADEH, O. et al. Forest Fire Susceptibility and Risk Mapping Using Social/Infrastructural Vulnerability and Environmental Variables. **Fire**, v. 2, n. 3, p. 50, 3 set. 2019. Disponível em: <<https://www.mdpi.com/2571-6255/2/3/50>>. Acesso em: 3 abr. 2020.

GHORBANZADEH, O.; BLASCHKE, T. Wildfire susceptibility evaluation by integrating an analytical network process approach into GIS-based analyses. 2018, [S.l.: s.n.], 2018.

GOLDARAG, Y. J.; MOHAMMADZADEH, A.; ARDAKANI, A. S. Fire Risk Assessment

Using Neural Network and Logistic Regression. **Journal of the Indian Society of Remote Sensing**, v. 44, n. 6, p. 885–894, 1 dez. 2016.

GOVERNMENT OF CANADA. **Types of wildland fires**. Disponível em: <<https://www.nrcan.gc.ca/our-natural-resources/forests-forestry/wildland-fires-insects-disturban/forest-fires/fire-behaviour/13145>>. Acesso em: 1 jun. 2020.

HAKIMI, S. L. Optimum Locations of Switching Centers and the Absolute Centers and Medians of a Graph. **Operations Research**, v. 12, n. 3, p. 450–459, 1 jun. 1964.

HAYKIN, S. **Redes Neurais. Princípios e Prática**. 2. ed. Porto Alegre: Bookman, 2003.

HELBINGEN JÚNIOR, C. **Manual operacional de bombeiros: prevenção e combate a incêndios florestais**. . Goiânia: [s.n.], 2017.

HERRERA-GRIMALDI, P. et al. Detection of trends and break points in temperature: the case of Umbria (Italy) and Guadalquivir Valley (Spain). **Acta Geophysica**, v. 66, n. 3, p. 329–343, 10 jun. 2018. Disponível em: <<http://link.springer.com/10.1007/s11600-018-0118-1>>.

HIGUERA, P. E. et al. The Changing Strength and Nature of Fire-Climate Relationships in the Northern Rocky Mountains, U.S.A., 1902-2008. **PLOS ONE**, v. 10, n. 6, p. e0127563, 26 jun. 2015. Disponível em: <<http://dx.plos.org/10.1371/journal.pone.0127563>>. Acesso em: 31 mar. 2020.

JULIUS, S. et al. **Preliminary review of adaptation options for climate-sensitive ecosystems and resources. National Parks**. [S.l: s.n.], 2008.

JUVANHOL, R. S. **Aprendizado de máquina na modelagem de incêndios florestais no estado do Espírito Santo**. 2017. 115 f. Tese (Doutorado em Ciências Florestais) - Universidade Federal do Espírito Santo, Jerônimo Monteiro, 2017.

KOLDEN, C.; ABATZOGLOU, J. Spatial Distribution of Wildfires Ignited under Katabatic versus Non-Katabatic Winds in Mediterranean Southern California USA. **Fire**, v. 1, n. 2, p. 19, 21 jun. 2018. Disponível em: <<http://www.mdpi.com/2571-6255/1/2/19>>. Acesso em: 3 abr. 2020.

KUSHLA, J. D.; RIPPLE, W. J. The role of terrain in a fire mosaic of a temperate

coniferous forest. **Forest Ecology and Management**, v. 95, n. 2, p. 97–107, 31 jul. 1997.

LAUTENBERGER, C. Mapping areas at elevated risk of large-scale structure loss using Monte Carlo simulation and wildland fire modeling. **Fire Safety Journal**, v. 91, p. 768–775, 1 jul. 2017.

LITTELL, J. S. et al. A review of the relationships between drought and forest fire in the United States. **Global Change Biology**, v. 22, n. 7, p. 2353–2369, 1 jul. 2016. Disponível em: <<http://doi.wiley.com/10.1111/gcb.13275>>. Acesso em: 26 mar. 2020.

LYNDON, G.; POMERANTZ, C.; DONEV, J. **Types of Forest Fires**. Disponível em: <https://energyeducation.ca/encyclopedia/Forest_fire>. Acesso em: 2 jan. 2020.

MARTÍNEZ, J.; VEGA-GARCIA, C.; CHUVIECO, E. Human-caused wildfire risk rating for prevention planning in Spain. **Journal of Environmental Management**, v. 90, n. 2, p. 1241–1252, 1 fev. 2009.

MATHIYALAGAN, V. et al. A WebGIS and geodatabase for Florida's wetlands. **Computers and Electronics in Agriculture**, v. 47, n. 1, p. 69–75, abr. 2005.

MATIN, M. A. et al. Understanding forest fire patterns and risk in Nepal using remote sensing, geographic information system and historical fire data. **International Journal of Wildland Fire**, v. 26, n. 4, p. 276–286, 2017.

MAVRIDIS, T.; SYMEONIDIS, A. L. Identifying valid search engine ranking factors in a Web 2.0 and Web 3.0 context for building efficient SEO mechanisms. **Engineering Applications of Artificial Intelligence**, v. 41, p. 75–91, maio 2015.

MOLLICONE, D.; EVA, H. D.; ACHARD, F. Ecology: Human role in Russian wild fires. **Nature**, v. 440, n. 7083, p. 436–437, 23 mar. 2006.

MORGAN, P. et al. Mapping fire regimes across time and space: understanding coarse and fine-scale fire patterns. **International Journal of Wildland Fire**, v. 10, n. 4, p. 329–342, 2001.

MORRIS, R. D. Web 3.0: Implications for Online Learning. **TechTrends**, v. 55, n. 1, p. 42–46, jan. 2011.

MOTA, P. H. S. et al. Forest fire hazard zoning in Mato Grosso State, Brazil. **Land Use**

Policy, v. 88, p. 104206, nov. 2019. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0264837719304624>>.

MOTTA, D. S. **Identificação dos fatores que influenciam no comportamento do fogo em incêndios florestais**. 2008. 32 f. Monografia (Graduação em Engenharia Florestal) - Universidade federal Rural do Rio de Janeiro, 2008.

MUDI, S. et al. Development of a WebGIS platform to generate biodiversity data using citizen science approach. **For. Resour. Resil. Conflicts**. [S.l.]: Elsevier, 2021. p. 17–31.

NELSON, R. M. Water Relations of Forest Fuels. **For. Fires**. [S.l.]: Elsevier, 2001. p. 79–149. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/B9780123866608500064>>.

NOLAN, R. et al. **Things you need to know about bushfire behaviour**. Disponível em: <<https://www.science.org.au/curious/earth-environment/things-you-need-know-about-bushfire-behaviour>>. Acesso em: 3 abr. 2020.

POURTAGHI, Z. S.; POURGHASEMI, H. R.; ROSSI, M. Forest fire susceptibility mapping in the Minudasht forests, Golestan province, Iran. **Environmental Earth Sciences**, v. 73, n. 4, p. 1515–1533, 26 jul. 2015.

PRUDENTE, T. **Geotecnologias aplicadas ao mapeamento de risco de incêndio florestal no Parque Nacional da Chapada dos Veadeiros e área de entorno**. 2010. 116 f. Geotecnologias aplicadas ao mapeamento de risco de incêndio florestal no Parque Nacional da Chapada dos Veadeiros e área de entorno, 2010. Disponível em: <<http://200.19.146.153/handle/123456789/16084>>. Acesso em: 1 abr. 2020.

PURVIS, M.; SAMBELLS, J.; TURNER, C. **Beginning Google Maps Applications with PHP and Ajax**. 1. ed. Berkeley, CA: Apress Berkeley, CA, 2006.

RÁCZ, S. Firefighting problems in case of large outdoor fires. **Muszaki Katonai kozlony**, v. 28, n. 4, p. 23–32, 2018.

RODRÍGUEZ Y SILVA, F. et al. Corrigendum to: Modelling suppression difficulty: current and future applications. **International Journal of Wildland Fire**, v. 29, n. 8, p. 752, 2020. Disponível em: <http://www.publish.csiro.au/?paper=WF19042_CO>.

SACHDEVA, S.; BHATIA, T.; VERMA, A. K. GIS-based evolutionary optimized Gradient Boosted Decision Trees for forest fire susceptibility mapping. **Natural Hazards**, v. 92, n. 3, p. 1399–1418, 1 jul. 2018.

SANTOS, J. F. L. dos. **Estimativa do teor de umidade da estepe gramínea-lenhosa para uso em índice de perigo de incêndios florestais**. 2020. 77 f. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal do Paraná, Curitiba., 2020.

SAYAD, Y. O.; MOUSANNIF, H.; AL MOATASSIME, H. Predictive modeling of wildfires: A new dataset and machine learning approach. **Fire Safety Journal**, v. 104, p. 130–146, 1 mar. 2019.

SEMERARO, T. et al. GIS Fuzzy Expert System for the assessment of ecosystems vulnerability to fire in managing Mediterranean natural protected areas. **Journal of Environmental Management**, v. 168, p. 94–103, 1 mar. 2016. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0301479715304072>>. Acesso em: 23 abr. 2020.

ŞEN, Z.; HABIB, Z. Spatial precipitation assessment with elevation by using point cumulative semivariogram technique. **Water Resources Management**, v. 14, n. 4, p. 311–325, 2000.

SILVA, F. et al. **VISUAL-SEVEIF, a tool for integrating the behavior simulation and economic evaluation of the impacts of wildfires**. [S.l: s.n.], 2013.

SIMÕES, M. G.; SHAW, I. S. **Controle E Modelagem Fuzzy**. 2. ed. São Paulo: Edgard Blucher, 2007.

SOARES, R. .; BATISTA, A. C.; NUNES, J. R. S. **Manual de prevenção e combate a incêndios florestais**. . Curitiba: FUPEF. , 2008

SOARES, R.; BATISTA, A. **Incêndios florestais: controle, efeitos e uso do fogo**. Curitiba, Paraná: UFPR, 2007. Disponível em: <<http://www.sidalc.net/cgi-bin/wxis.exe/?IsisScript=AGB.xis&method=post&formato=2&cantidad=1&expresion=mfn=230783>>. Acesso em: 30 mar. 2020.

SOARES, R. V.; BATISTA, A. C.; TETTO, A. F. **Incêndios Florestais: controle, efeitos e uso do fogo**. Curitiba: Universidade Federal do Paraná, 2017.

TETENS, O. Über einige meteorologische Begriffe. **Z. geophys**, v. 6, p. 297–309, 1930.

TIEN BUI, D. et al. A hybrid artificial intelligence approach using GIS-based neural-fuzzy inference system and particle swarm optimization for forest fire susceptibility modeling at a tropical area. **Agricultural and Forest Meteorology**, v. 233, p. 32–44, 15 fev. 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168192316304269#!>>. Acesso em: 7 out. 2019.

TV GAZETA. Incêndio em parque de Itaúnas segue sem controle após 18 dias. **G1**, Vitória, 28 dez. 2015. Disponível em: <<http://g1.globo.com/espirito-santo/noticia/2015/12/incendio-em-parque-de-itaunas-segue-sem-controle-apos-18-dias.html>>.

VASILAKOS, C. et al. Integrating new methods and tools in fire danger rating. **International Journal of Wildland Fire**, v. 16, n. 3, p. 306, 20 jul. 2007. Disponível em: <<http://www.publish.csiro.au/?paper=WF05091>>. Acesso em: 2 abr. 2020.

WESTERLING, A. L. Increasing western US forest wildfire activity: sensitivity to changes in the timing of spring. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v. 371, n. 1696, jun. 2016.

WHITE, B. L. A.; RIBEIRO, G. T.; SOUZA, R. M. O uso do BehavePlus como ferramenta para modelagem do comportamento e efeito do fogo. **Pesquisa Florestal Brasileira**, v. 33, n. 73, p. 73–83, mar. 2013.

YANG, J. et al. Spatial patterns of modern period human-caused fire occurrence in the Missouri Ozark Highlands. **Forest science**, v. 53, n. 1, p. 1–15, 2007.

ZASTROW, M. Data visualization: Science on the map. **Nature**, v. 519, n. 7541, p. 119–120, mar. 2015.

ZEFERINO, J. A. Optimizing the location of aerial resources to combat wildfires: a case study of Portugal. **Natural Hazards**, v. 100, n. 3, p. 1195–1213, 24 fev. 2020. Disponível em: <<http://link.springer.com/10.1007/s11069-020-03856-6>>. Acesso em: 26 mar. 2020.

8 APÊNDICE

Apêndice 2. Análise descritiva dos fatores condicionantes a ocorrência de incêndios florestais para a região de Andaluzia.

Variável (un)	Classes	Frequência		
		Absoluta	Relativa	Acumulada
DEM (m)	[1; 161,5)	718	33,93	33,93
	[161,5; 355)	377	17,82	51,75
	[355; 545,5)	320	15,12	66,87
	[545,5; 748)	330	15,60	82,47
	[748; 996,5)	220	10,40	92,86
	[996,5; 1322,5)	108	5,10	97,97
	[1322,5; 2043]	43	2,03	100,00
Slope (°)	[0; 1,31)	589	27,84	27,84
	[1,31; 2,76)	487	23,02	50,85
	[2,76; 4,66)	332	15,69	66,54
	[4,66; 7,37)	290	13,71	80,25
	[7,37; 10,96)	195	9,22	89,46
	[10,96; 16,08)	179	8,46	97,92
	[16,08; 24,76]	44	2,08	100,00
orientação do terreno	plano [-1)	0	0	0
	norte [0; 22,5) & [337,5; 360)	221	10,44	10,44
	nordeste [22,5; 67,5)	176	8,32	18,76
	leste [67,5; 112,5)	233	11,01	29,77
	sudeste [112,5; 157,5)	289	13,66	43,43
	sul [157,5; 202,5)	395	18,67	62,10
	sudoeste [202,5; 247,5)	291	13,75	75,85
	oeste [247,5; 292,5)	311	14,70	90,55
	noroeste [292,5; 337,5)	200	9,45	100,00
TempMax (°C)	[20,68; 26,02)	64	3,03	3,03
	[26,02; 27,47)	305	14,43	17,46
	[27,47; 28,30)	538	25,45	42,90
	[28,30; 29,14)	444	21,00	63,91
	[29,14; 30,04)	340	16,08	79,99
	[30,04; 31,02)	300	14,19	94,18
	[31,02; 31,92]	123	5,82	100,00
TempMin (°C)	[6,43; 12,26)	56	2,65	2,65
	[12,26; 14,34)	126	5,96	8,61

	[14,34; 15,77)	350	16,56	25,17
	[15,77; 16,90)	436	20,62	45,79
	[16,90; 17,89)	468	22,14	67,93
	[17,89; 18,79)	385	18,21	86,14
	[18,79; 19,94]	293	13,86	100,00
Precipitação média (mm)	[16,43; 21,70)	93	4,40	4,40
	[21,70; 24,56)	253	11,97	16,37
	[24,56; 26,73)	261	12,35	28,71
	[26,73; 28,82)	326	15,42	44,13
	[28,82; 30,75)	433	20,48	64,62
	[30,75; 33,28)	427	20,20	84,82
	[33,28; 42,70]	321	15,18	100,00
Umidade Relativa (%)	[61,04; 63,41)	539	25,50	25,50
	[63,41; 65,32)	445	21,05	46,55
	[65,32; 67,10)	332	15,70	62,25
	[67,10; 68,90)	284	13,43	75,69
	[68,90; 70,65)	190	8,99	84,67
	[70,65; 72,42)	159	7,52	92,19
	[72,42; 76,13]	165	7,81	100,00
Velocidade do vento (m,s⁻¹)	[2,39; 2,57)	189	8,94	8,94
	[2,57; 2,74)	369	17,46	26,40
	[2,74; 2,92)	435	20,58	46,97
	[2,92; 3,13)	332	15,70	62,68
	[3,13; 3,35)	334	15,80	78,48
	[3,35; 3,63)	389	18,40	96,88
	[3,63; 4,15]	66	3,12	100,00
Umidade do solo (mm)	[4,10; 8,92)	329	15,56	15,56
	[8,92; 13,16)	350	16,56	32,12
	[13,16; 17,64)	346	16,37	48,49
	[17,64; 21,73)	423	20,01	68,50
	[21,73; 26,05)	401	18,97	87,46
	[26,05; 32,04)	152	7,19	94,65
	[32,04; 41,74]	113	5,35	100,00
NDVI	[0,12; 0,23)	211	10,17	10,17
	[0,23; 0,29)	399	19,24	29,41
	[0,29; 0,35)	456	21,99	51,40
	[0,35; 0,41)	421	20,30	71,70
	[0,41; 0,48)	286	13,79	85,49
	[0,48; 0,57)	198	9,55	95,03
	[0,57; 0,78]	103	4,97	100,00
IAF (m²/m²)	[1,56; 4,36)	327	16,01	16,01

	[4,36; 6,01)	544	26,63	42,63
	[6,01; 7,82)	469	22,96	65,59
	[7,82; 10,12)	346	16,94	82,53
	[10,12; 13,64)	248	12,14	94,66
	[13,64; 14,16)	108	5,29	99,95
	[14,90; 25,5]	1	0,05	100,00
Distância de estradas (m)	[0; 288,8325)	977	46,17	46,17
	[288,83; 734,33)	573	27,08	73,25
	[734,33; 1342,88)	289	13,66	86,91
	[1342,88; 2287,56)	176	8,32	95,23
	[2287,56; 4188,47)	79	3,73	98,96
	[4188,47; 8194,10)	20	0,95	99,91
	[8194,10; 12586,58]	2	0,09	100,00
Distância de residências (m)	[0; 619,64)	598	28,26	28,26
	[619,64; 1551,03)	553	26,13	54,40
	[1551,03; 2758,45)	388	18,34	72,73
	[2758,45; 4248,06)	277	13,09	85,82
	[4248,06; 6298,53)	178	8,41	94,23
	[6298,53; 10247,01)	101	4,77	99,01
	[10247,01; 21495,28]	21	0,99	100,00
Uso e Ocupação da Terra	Agricultura	333	15,74	15,74
	Arbustos	452	21,36	37,10
	Corpos água	4	0,19	37,29
	Floresta aberta	844	39,89	77,17
	Floresta fechada	129	6,10	83,27
	Urbano	181	8,55	91,82
	Vegetação herbácea	173	8,18	100,00