

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

**Sistema de IA baseado em drones para monitoramento e
previsão de risco de incêndios florestais**

Julio Joel Roncal Aguilar

Trabalho de Conclusão de Curso
MBA em Inteligência Artificial e Big Data

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Sistema de IA baseado em drones para
monitoramento e previsão de risco de
incêndios florestais

Julio Joel Roncal Aguilar

USP - São Carlos
2025

Julio Joel Roncal Aguilar

Sistema de IA baseado em drones para monitoramento e previsão de risco de incêndios florestais

Trabalho de conclusão de curso apresentado ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientadora: Profa. Dra. Rosane Minghim

USP - São Carlos

2025

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

R769s Roncal Aguilar, Julio Joel
 Sistema de IA baseado em drones para
 monitoramento e previsão de risco de incêndios
 florestais / Julio Joel Roncal Aguilar; orientador
 Rosane Minghim. -- São Carlos, 2025.
 p.

Trabalho de conclusão de curso (MBA em
Inteligência Artificial e Big Data) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2025.

1. Aerial Drones. 2. Inteligência Artificial. 3.
Machine Learning. I. Minghim, Rosane, orient. II.
Título.

Bibliotecários responsáveis pela estrutura de catalogação da publicação de acordo com a AACR2:
Gláucia Maria Saia Cristianini - CRB - 8/4938
Juliana de Souza Moraes - CRB - 8/6176

DEDICATÓRIA

*Dedico este trabalho a você, teu
olhar brilha como estrela a dançar,
mesmo quando a noite insiste em
tremor, e eu sou teu porto, pronto a
te amar. (Maiara J. Wachholz)*

AGRADECIMENTOS

Um agradecimento para a Dra. Rosane Minghim, que muito me ensinou contribuindo para o meu crescimento científico e em especial para a Dra. Solange Oliveira Rezende e o Dr. Filipe Verri, pelo incentivo e apoio nos momentos de dificuldade e orientação no desenvolvimento da pesquisa.

RESUMO

AGUILAR, J.J.R. **Sistema de IA baseado em drones para monitoramento e previsão de risco de incêndios florestais.** 2025. 41 f. Trabalho de conclusão de curso (MBA em Inteligência Artificial e Big Data) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

Os incêndios florestais representam uma ameaça significativa aos ecossistemas, vidas humanas e infraestrutura em todo o mundo. Métodos tradicionais de detecção e avaliação de risco de incêndios florestais frequentemente apresentam limitações, como a detecção tardia e baixa confiança em certas regiões. Neste trabalho de conclusão de curso, é proposto um sistema computacional inovador baseado em aprendizado de máquina para avaliação de risco de incêndios florestais, utilizando dados coletados por drones. O sistema é capaz de integrar diversos sensores para capturar dados espaciais e temporais sobre fatores ambientais, como temperatura, umidade e vegetação. Ao utilizar dados de alta resolução coletados por meio de missões autônomas de drones, o sistema aprimora a estimativa de risco de incêndios e permite o planejamento proativo de missões. Embora o sistema tenha sido projetado principalmente para monitoramento de incêndios florestais com dados coletados por drones, ele pode ser facilmente adaptado para outras aplicações de monitoramento ambiental e fontes de dados diversas. Por meio de um processo abrangente de avaliação e validação em ambientes reais e simulados ficou comprovado a eficácia da abordagem.

Palavras-chave: Drones aéreos, inteligência artificial, aprendizado de máquina, detecção de incêndios florestais.

ABSTRACT

AGUILAR, J.J.R. **Drone-Based AI System for Wildfire Monitoring and Risk Prediction.** 2025. 41 f. Trabalho de conclusão de curso (MBA em Inteligência Artificial e Big Data) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

Wildfires pose a significant threat to ecosystems, human lives, and infrastructure worldwide. Traditional methods for detecting and assessing wildfire risks often have limitations, such as delayed detection and low confidence in certain areas. This thesis proposes an innovative computational system based on machine learning for wildfire risk assessment, utilizing data collected by drones. The system can integrate various sensors to capture spatiotemporal data on environmental factors such as temperature, humidity, and vegetation. By using high-resolution data gathered through autonomous drone missions, the system enhances wildfire risk estimation and enables proactive mission planning. Although the system was primarily designed for wildfire monitoring using drone-collected data, it can be easily adapted for other environmental monitoring applications and various data sources. Through a comprehensive evaluation and validation process in real and simulated environments, the effectiveness of the approach was proven.

Keywords: Aerial drones, artificial intelligence, machine learning, wildfire detection.

LISTA DE ILUSTRAÇÕES

Figura 1 – Arquitetura do Framework	22
Figura 2 – Resumo das missões de coleta de dados realizadas.	24
Figura 3 – Sobrevoou do drone em São José dos Campos/SP, Brasil.....	24
Figura 4 – (a) Imagem de drone do mundo real, (b) cenário simulado	28
Figura 5 – (a) Detecção mundo simulado, (b) Detecção mundo real	30

LISTA DE TABELAS

Tabela 1 – Sobrevoou do drone em São José dos Campos/SP, Brasil.....25

SUMÁRIO

1 INTRODUÇÃO.....	15
2 FUNDAMENTAÇÃO TEÓRICA.....	17
2.1 Modelos de predição de Incêndios Florestais.....	17
2.2 Variáveis Independentes e Processamento de Dados.....	18
2.3 Avanços em Deep Learning.....	20
2.4 Avaliação de modelos e métricas	20
2.5 Integração e Analise.....	20
3 DESENVOLVIMENTO.....	21
3.1 Framework Proposto.....	21
3.2 Aquisição de dados e Integração de sensores.....	22
3.3 Gerenciamento e Fusão de dados.....	22
3.4 Inteligência Artificial e Machine Learning.....	23
3.5 Console do operador.....	23
3.6 Aquisição de dados e integração com sensores do drone.....	23
3.7 Transformação de Dados.....	25
3.8 Simulação e Testes no mundo real.....	26
4 ANÁLISE E CONCLUSÃO.....	29
REVISÃO BIBLIOGRÁFICA.....	33

1 INTRODUÇÃO

Os incêndios florestais são um dos desastres naturais mais devastadores, causando perdas econômicas significativas, danos ecológicos e graves efeitos à saúde. Ao longo de 2023, o Serviço de Monitoramento da Atmosfera Copernicus (CAMS) monitorou incêndios florestais em todo o mundo. Usando seu Sistema Global de Assimilação de Fogo (GFAS), o CAMS forneceu dados precisos sobre a intensidade dos incêndios e as emissões de carbono (CAMS, 2023). Muitas regiões experimentaram atividade de incêndios florestais recorde naquele ano. Por exemplo, o Canadá registrou as maiores emissões de carbono por incêndios florestais nos registros do CAMS, que datam de 2003. A Grécia também enfrentou o maior incêndio florestal da União Europeia até hoje. De acordo com as estimativas do CAMS os incêndios florestais globais geraram aproximadamente 2.170 megatoneladas de emissões de carbono.

De acordo com um relatório do Programa das Nações Unidas para o Meio Ambiente (das siglas em inglês, UNEP) e o GRID-Arendal, mudanças no clima e no uso da terra tornam os incêndios florestais mais frequentes e intensos. Eles esperam um aumento global de incêndios extremos de até 14% até 2030, 30% até o final de 2050 e 50% até o final do século (UNEP, 2024)

Os impactos dos incêndios florestais não se limitam ao meio ambiente. Eles também têm efeitos econômicos, ecológicos, e na saúde física e mental das pessoas (GRANT et al., 2022). Esses impactos se estendem por dias, semanas e até anos após as chamas cessarem. No Brasil, a região do Pantanal tem sido particularmente afetada pelos incêndios florestais. Com as rápidas mudanças climáticas, a região tem experimentado um aumento significativo na temperatura (LIBONATI et al., 2022), (MARQUES et al., 2021). Além disso, a diminuição das precipitações (LAZARO et al., 2020), (GEIRINHAS et al., 2023) leva a uma queda na umidade do solo e a um aumento no número de dias sem chuva. Essa situação tem levado a uma queda na massa de água no solo durante a estação de seca, o que tem aumentado o risco de incêndios florestais.

Consequentemente, em 2020, a ocorrência de incêndios florestais atingiu níveis recordes, com mais de 40.000 km² afetados. A extensão da área afetada representa um aumento de 376% em comparação com a média anual da área queimada nas duas últimas décadas, dobrando o valor alcançado em 2019 (GARCIA et al., 2021). A extensão dos incêndios florestais nessa região tem sido associada à ocorrência de ondas de calor (SILVA et al., 2022) que estão aumentando junto com as condições extremas de calor. Espera-se que as mudanças climáticas futuras proporcionem condições (LIBONATI et al., 2022) ainda mais favoráveis para

a ocorrência de incêndios florestais (MARENKO; ALVES; TORRES, 2016), (RIBEIRO et al., 2022). Ao mesmo tempo, os avanços no uso agrícola da região do Pantanal impulsionaram o aumento da prática de queimar áreas para preparar o solo para uso posterior. Um cenário de previsão para 2030 mostra que, caso medidas de proteção ambiental e combate a incêndios não sejam adotadas, neste ano, 20% das áreas do Pantanal serão destinadas ao uso agrícola e de pastagem (MARQUES et al., 2021).

Apesar dos problemas causados pelos incêndios florestais no Brasil, iniciativas estão sendo implementadas para promover um gerenciamento e controle de incêndios mais responsável e sustentável. Por exemplo, o plano de ação para o manejo integrado do fogo no bioma Pantanal (GARCIA et al., 2021) visa melhorar a eficiência e viabilidade econômica do manejo do fogo. Tais iniciativas buscam integrar conhecimentos tradicionais, locais e ecológicos com o conhecimento científico existente para desenvolver uma estratégia coletiva dentro do contexto socioecológico. As comunidades são incentivadas a colaborar na criação de uma rede cooperativa para a prevenção de incêndios florestais, priorizando áreas para investimento financeiro, manejo e proteção (UNEP, 2024)

Essas iniciativas estão alinhadas com o pensamento e os esforços internacionais, como destacado no relatório do UNEP e GRID-Arendal (UNEP, 2024) que pede uma mudança significativa nos gastos dos governos com incêndios florestais – de reação e resposta para prevenção e preparação. Também há uma necessidade urgente de uma compreensão aprimorada dos benefícios da prevenção de incêndios florestais, que podem ser alcançados por meio de atividades de monitoramento aprimoradas.

Atualmente, o Brasil também possui o Portal do Programa de Incêndios Florestais do INPE, que agrega dados sobre precipitação, temperatura, umidade, topografia e vegetação para calcular o risco de incêndio. No entanto, devido à ampla cobertura do sistema e à granularidade da coleta de dados, essa abordagem tende a ser suscetível à detecção tardia de incêndios e à baixa confiança em determinadas regiões. Embora os sensores fixos de alta resolução sejam limitados a pequenas áreas e careçam de flexibilidade de mobilidade, uma abordagem alternativa e possível solução envolve o uso de missões autônomas de drones para coletar dados de alta resolução em regiões de interesse. A escolha da região de interesse pode ser baseada na estimativa de risco do sistema ou em outros critérios, como a escassez de dados históricos ou baixa confiança na estimativa de risco para essa área específica. Essa abordagem pode ser a base de um sistema de prevenção e monitoramento muito mais proativo, capaz de, com base em suas previsões, decidir os melhores locais para novas missões, analisando melhor as regiões de alto risco ou coletando mais dados em áreas previamente sub amostradas.

1.1 Objetivos

O objetivo é desenvolver um sistema computacional baseado no Aprendizado de Máquina (das siglas em inglês, ML) para calcular o risco de incêndios florestais em Veículos Aéreos Não Tripulados (das siglas em inglês, UAVs), particularmente drones. O sistema permitirá a estimativa do risco de incêndios florestais. Essa abordagem está alinhada com as três etapas do gerenciamento de incêndios florestais: pré-incêndio, incêndio ativo e pós-incêndio. Segundo Boroujeni *et al.* (2024), essas três etapas são descritas como:

- Pré-incêndio: atividades como medição da vegetação combustível baseada em visão computacional para avaliar e mitigar o risco de incêndio antes que ele ocorra;
- Incêndio ativo: tarefas como modelagem de crescimento do fogo para prever e gerenciar o comportamento de um incêndio em andamento; e
- Pós-incêndio: esforços incluindo planejamento de evacuação e avaliação dos efeitos do incêndio.

2 FUNDAMENTAÇÃO TEÓRICA

Os incêndios florestais representam um dos desastres naturais mais prevalentes. As projeções antecipam uma escalada contínua dessa tendência, especialmente em resposta à atividade antropogênica (COOGAN *et al.*, 2019)

A capacidade de aprimorar os sistemas de detecção de incêndios florestais e calcular o risco de incêndio de forma autônoma e automática com a ajuda de UAVs e, potencialmente, aeronaves tripuladas, atende à demanda do Ministério da Defesa, liderado pela Força Aérea. Por exemplo, o Plano de Ciência, Tecnologia e Inovação da Aeronáutica PCA 11-217/2018 prevê o estudo e desenvolvimento de "Veículos Aéreos Não Tripulados para missões de defesa e operações de defesa civil, segurança pública e monitoramento ambiental".

2.1 Modelos de predição de Incêndios Florestais

Entender e prever o risco de incêndios florestais é um problema multifacetado que tem atraído significativa atenção da pesquisa. Diversos estudos têm se concentrado em diferentes aspectos da predição de risco de incêndios florestais.

Modelos estatísticos tradicionais e técnicas de ML têm sido amplamente utilizados na previsão de incêndios florestais. Boroujeni *et al.* (2024) fornecem uma revisão abrangente sobre os modelos estatísticos e de ML utilizados na predição de incêndios florestais. Seu trabalho

enfatiza a necessidade de modelos robustos, capazes de lidar com interações complexas entre variáveis.

Rubí e Gondim (2024) compararam vários modelos de ML para prever o risco de ocorrência de incêndios florestais na região do Distrito Federal do Brasil. Eles descobriram que o risco de incêndio pode ser previsto com uma precisão de 0,99. O estudo também destacou que os modelos foram mais sensíveis ao Índice de Vegetação por Diferença Normalizada (NDVI), pressão atmosférica e umidade relativa. Incorporando um conjunto de dados abrangente, enriquecido com dados abertos do governo brasileiro, eles alcançaram alta precisão de predição, demonstrando o potencial do ML na avaliação do risco de incêndios florestais.

Kabir *et al.* (2024) focam na predição de incêndios florestais nos Estados Unidos, utilizando modelos de previsão de séries temporais. Eles empregam o modelo *Neural Basis Expansion Analysis for Time Series* (N-BEATS) para prever a área total queimada por incêndios florestais semanal e mensalmente. Seu modelo demonstra um desempenho superior em relação a outros modelos de ponta, destacando o potencial das técnicas avançadas de previsão de séries temporais na predição de incêndios florestais. Neste sistema proposto se baseia em avanços recentes ao focar no cálculo de risco de incêndios florestais com base em ML. Ele integra dados de múltiplos sensores em drones, incluindo uma variação da banda visível do NDVI (vNDVI), umidade e temperatura. O vNDVI foi selecionado com base na pesquisa de Costa, Nunes e Ampatzidis (2020), que demonstrou que essa variação da banda visível do NDVI fornece uma ferramenta rápida e de baixo custo para avaliação de informações de vegetação. Utilizando câmeras RGB de baixo custo e um algoritmo genético, esse método estima valores de NDVI a partir de mapas RGB, com um Erro Percentual Médio (MPE) de 6,89% e um Erro Absoluto Médio (MAE) de 0,052. Além disso, o sistema proposto está preparado para incorporar qualquer outro tipo de informação que possa ser coletada pelos sensores dos UAVs. Essa integração facilita o planejamento eficiente de missões e a análise de dados em tempo real, aprimorando a estimativa de risco de incêndios florestais, melhorando a detecção precoce e apoiando estratégias abrangentes de gestão de incêndios florestais.

2.2 Variáveis Independentes e Processamento de Dados

Xu Z., Li e Xu L. (2024) discutem a ampla gama de variáveis independentes cruciais para a predição de incêndios florestais. Essas variáveis incluem condições climáticas e meteorológicas, fatores socioeconômicos, características do terreno e hidrológicas, além de registros históricos de incêndios florestais. Os autores destacam diversas técnicas de

processamento de dados para lidar com os diferentes formatos e resoluções dessas variáveis. Eles também enfatizam a importância de abordar a colinearidade e avaliar a relevância das diferentes variáveis.

Rubí e Gondim (2024) destacam o papel de variáveis como NDVI, pressão atmosférica e umidade relativa na predição de risco de incêndios florestais. Eles demonstram como a seleção e o processamento cuidadosos dessas variáveis podem levar a uma alta precisão preditiva em modelos de ML. O NDVI e o vNDVI são ferramentas cruciais em pesquisas de predição de incêndios florestais utilizando drones, devido à sua capacidade de monitorar a saúde da vegetação com precisão [COSTA; NUNES; AMPATZIDIS, 2020]. O NDVI mede a diferença entre a reflexão da luz no infravermelho próximo e no vermelho, com valores mais altos indicando vegetação mais saudável (ROUSE et al., 1974). Já o vNDVI, que incorpora bandas espectrais visíveis e de infravermelho próximo, aumenta a sensibilidade à vegetação estressada ou escassa, tornando-o mais sensível a mudanças na refletância visível causadas pelo fogo segundo Costa, Nunes e Ampatzidis (2020). Esses índices possibilitam a detecção precoce de áreas propensas a incêndios, identificando vegetação seca ou estressada suscetível a incêndios florestais (Hunt et al., 2013).

A integração de dados de índices de vegetação com algoritmos de ML pode identificar padrões e correlações com ocorrências históricas de incêndios florestais, aprimorando sistemas de alerta precoce e medidas preventivas. As capacidades de análise espaço-temporal desses índices permitem o acompanhamento das mudanças na saúde da vegetação ao longo do tempo e entre regiões, auxiliando na previsão de riscos sazonais de incêndios florestais e na avaliação do impacto das mudanças climáticas (HUETE et al., 2002). O uso de drones para coleta de dados é uma alternativa econômica e flexível em comparação com métodos tradicionais, permitindo monitoramento mais frequente e abrangente. A adaptabilidade dos índices de vegetação sugeridos a diversos ambientes garante sua aplicabilidade em diferentes regiões, aumentando a generalização dos modelos de predição de incêndios florestais.

Além disso, a integração de dados de NDVI e vNDVI com outras variáveis ambientais, como temperatura e umidade, enriquece os conjuntos de dados e melhora o poder preditivo dos modelos de ML, resultando em avaliações de risco de incêndios florestais mais abrangentes.

Adicionalmente, Vilar *et al* (2021) modelaram a probabilidade de incêndios florestais na bacia do Mediterrâneo, na Espanha, utilizando como variáveis preditivas a densidade habitacional da região, a distância até áreas povoadas, o uso do solo, a distância e densidade de estradas, e a interface entre diferentes usos do solo (como floresta e agricultura). A referência da pesquisa de Syphard et al (2018) que estuda a sensibilidade de incêndios florestais a fatores

geográficos, climáticos e antropogênicos, encontrando que os níveis de precipitação e as inclinações do terreno são variáveis essenciais para o fenômeno. Consequentemente, Zhai *et al* (2023) identificaram que incêndios em florestas tendem a aumentar em frequência em terrenos com maior inclinação, exceto para inclinações superiores a 25 graus.

2.3 Avanços em Deep Learning

Avanços recentes em *Deep Learning* (DL) têm mostrado resultados promissores na predição de risco de incêndios florestais. Xu *et al.* (2024) discutem principalmente a aplicação de modelos de DL e suas métricas de avaliação de desempenho. Eles destacam a necessidade de algoritmos mais eficazes para previsão de séries temporais e o uso de dados tridimensionais, incluindo informações sobre combustível do solo e do tronco. Essa revisão abrangente sobre técnicas de DL e métricas de avaliação é essencial para entender as capacidades e limitações atuais desses modelos.

Shamta *et al* (2024) concentram-se no desenvolvimento de um sistema de vigilância baseado em DL para detecção precoce de incêndios florestais usando UAVs. Eles analisam o desempenho de vários modelos de DL na identificação de incêndios florestais, incluindo YOLOv8 e YOLOv5. O sistema utiliza detecção em tempo real e inclui uma interface de estação terrestre para exibição de dados e planejamento de intervenções. Seus resultados mostram alta precisão na detecção de incêndios florestais, demonstrando a eficácia dos algoritmos de DL em aprimorar a vigilância de incêndios florestais baseada em UAVs.

2.4 Avaliação de modelos e métricas

Rubí e Gondim (2024) destacam a importância da análise de sensibilidade de variáveis na melhoria da precisão dos modelos. Seu estudo demonstra como a avaliação cuidadosa do desempenho dos modelos pode levar a melhorias significativas na precisão das previsões.

2.5 Integração e Analise

Kanand *et al.* (2020) discutem a integração de UAS, tecnologias multisensores e redes móveis 5G para a detecção de incêndios florestais e monitoramento de desastres. O projeto em Saxônia, Alemanha, utiliza câmeras de aplicação infravermelho térmico para detectar fumaça ou pontos de calor, combinando dados de múltiplas observações para análise automatizada e localização. Essa abordagem demonstra o potencial das tecnologias de fusão de sensores e das

redes avançadas para aprimorar a precisão e a eficiência dos sistemas de detecção de incêndios florestais.

Rashid *et al.* (2020) apresentam o *CompDrone*, uma estrutura que combina modelagem computacional de incêndios florestais com sensoriamento por drones orientado por redes sociais para monitorar a propagação de incêndios florestais. O *CompDrone* aborda desafios como a disponibilidade limitada de sinais sociais em regiões remotas e a necessidade de estratégias eficazes de despacho de drones. Sua avaliação demonstra que o *CompDrone* supera os métodos existentes na previsão da propagação de incêndios florestais, destacando o potencial da integração de modelos computacionais com SDS para monitoramento confiável de incêndios.

3 DESENVOLVIMENTO

3.1 Framework Proposto

O *framework* proposto para previsão e gestão de riscos de incêndios florestais utiliza algoritmos avançados de ML e tecnologia de drones autônomos para melhorar o monitoramento e a gestão de áreas propensas a incêndios.

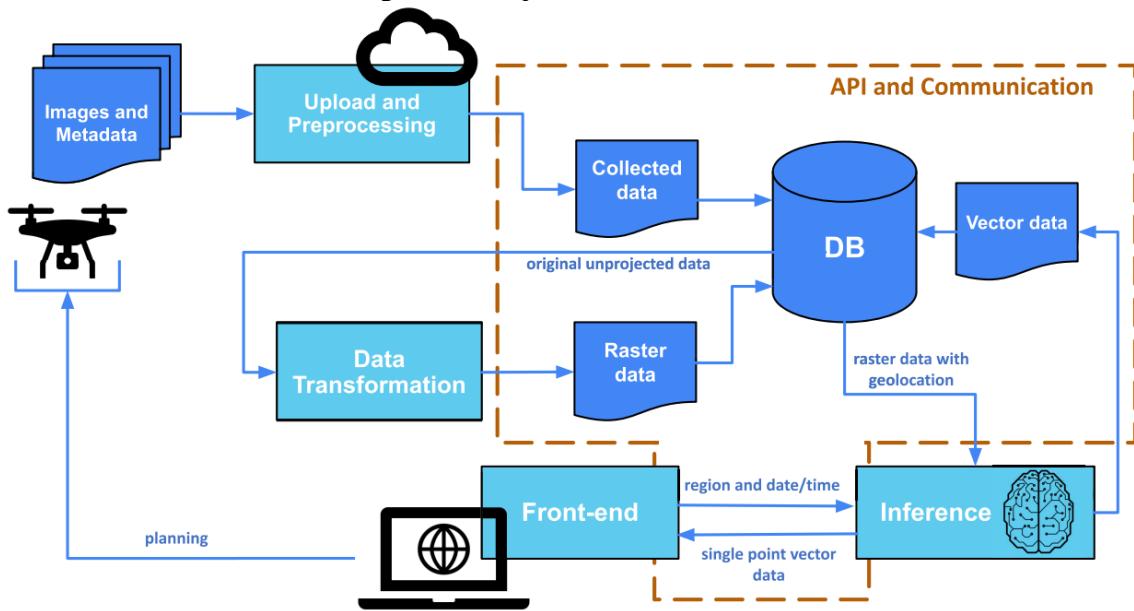
Os componentes conceituais gerais do *framework* abrangem diversos elementos-chave, cada um representando um aspecto crítico do sistema. Esses componentes incluem: aquisição de dados e integração de sensores, gestão e fusão de dados, API e comunicação, IA e ML, console do operador, e hardware embarcado. Juntos, esses elementos formam uma solução abrangente para previsão e gestão de riscos de incêndios florestais. Neste trabalho de conclusão de curso se abordará a parte do desenvolvimento de algoritmos de ML.

A arquitetura detalhada do sistema, incluindo os relacionamentos e o fluxo de dados entre subsistemas, é apresentada na Figura 1. Os dados provêm de sensores embutidos nos drones. Os dados são processados e armazenados em um banco de dados. Um processo de transformação é aplicado aos dados brutos para gerar um conjunto de dados em um formato padrão — optou-se pelo formato GeoJSON para essa finalidade.

Um módulo de inferência realiza duas tarefas principais: extrair características dos dados *raster* (tipo de metadados) — criando, efetivamente, dados vetoriais — e prever o valor da variável alvo nas regiões de interesse. O módulo de interface, chamado de console do operador, é responsável por exibir não apenas os resultados das inferências, mas também o nível de confiança das previsões. O console do operador também exibe a localização do drone e planeja a próxima coleta de dados.

Abaixo, mostrasse uma visão geral desses subsistemas.

Figura 1 – Arquitetura do Framework



Fonte: O autor (2025)

3.2 Aquisição de dados e Integração de sensores

O subsistema de aquisição de dados coleta informações de alta resolução relevantes às condições de incêndios florestais. Isso inclui imagens no espectro visível, imagens térmicas, umidade, temperatura e outros dados ambientais. Esses dados podem ser coletados de sensores reais, garantindo uma cobertura abrangente e flexibilidade na coleta de informações. Portanto, a aquisição de dados está mais relacionada à identificação dos dados ambientais relevantes a serem coletados do que à definição dos sensores.

Alguns dados ambientais, como o índice vNDVI (COSTA; NUNES; AMPATZIDIS, 2020), são derivados dos dados brutos coletados pelos sensores. O subsistema de aquisição de dados é responsável por processar esses dados brutos para gerar os dados derivados. Além disso, esse subsistema garante que os dados coletados sejam corretamente anotados com metadados, como geolocalização, marca temporal, tipo de sensor e outras informações relevantes.

3.3 Gerenciamento e Fusão de dados

O subsistema de gerenciamento e fusão de dados é responsável por armazenar, organizar e processar os dados coletados pelos sensores. Este subsistema garante que os dados sejam armazenados corretamente em um banco de dados, permitindo sua recuperação e

processamento de forma eficiente. Ele também lida com a fusão de dados provenientes de múltiplos sensores, assegurando que os dados sejam devidamente integrados e sincronizados. Considerando a natureza espaço-temporal dos dados coletados, existem dois tipos gerais de dados: dados raster e dados vetoriais. Dados raster representam matrizes densas de dados, como imagens ou mapas de temperatura. Já os dados vetoriais representam um único valor numérico associado a uma localização geográfica específica, como o nível de umidade ou a presença de um objeto.

3.4 Inteligência Artificial e ML

Destaca-se o uso de algoritmos de DL e visão computacional para extração de características em dados *raster*. Como o monitoramento ambiental consiste em acompanhar certas variáveis ao longo do tempo e do espaço, o uso de visão computacional para processar dados raster é essencial para que o sistema extraia as características de interesse a partir dos dados brutos. Por exemplo, pode haver interesse em observar o número de árvores em uma região específica. Nesse caso, o sistema deve ser capaz de detectar as árvores na imagem e contá-las — convertendo efetivamente os dados raster em dados vetoriais.

3.5 Console do operador

A console do operador fornece uma interface amigável para visualizar as previsões e os resultados do sistema. Essa ferramenta é essencial para a tomada de decisões, pois permite a visualização das previsões de risco de incêndios florestais em um mapa

3.6 Aquisição de dados e integração com sensores do drone

A aquisição de dados para este estudo envolveu a coleta de informações de sensores reais e fontes simuladas, garantindo cobertura abrangente e flexibilidade.

Um componente essencial da estratégia de aquisição de dados foi o uso de um drone DJI M30T emprestado pelo Instituto Tecnológico de Aeronáutica (ITA), que realizou um total de 37 voos, acumulando 3 horas e 34 minutos de tempo de voo. O drone foi empregado para capturar dados em tempo real em diversas localidades e condições ambientais. A Figura 2 apresenta um resumo das missões de coleta de dados realizadas.

Figura 2 – Resumo das missões de coleta de dados realizadas



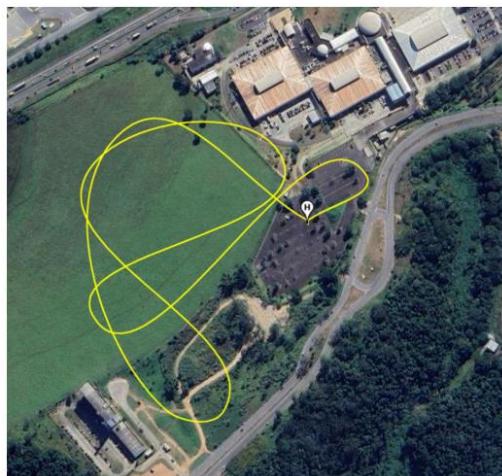
Fonte: O autor (2025)

A maioria dos voos foi realizada em São José dos Campos/SP, Brasil, nas proximidades do “Parque de Inovação Tecnológica”, caracterizado por variações significativas no uso e cobertura do solo (Figura 3). A captura de dados durante as estações secas também facilitou a variação nos índices de vegetação.

Durante esses voos, todas as 4 câmeras do drone foram utilizadas, capturando imagens em luz visível com abertura ampla, luz visível padrão, visível com zoom analógico e no espectro infravermelho.

A sincronização das imagens com os dados de telemetria (incluindo posicionamento geográfico, horário, etc.) exigiu o desenvolvimento de uma ferramenta de software de código aberto, disponível publicamente no GitHub (<https://github.com/drone-comp/m30ttools>).

Figura 3 – Sobrevoou do drone em São José dos Campos/SP, Brasil.



Fonte: O autor (2025)

O sistema embarcado desenvolvido permitiu ainda a captura de dados de temperatura e umidade durante os voos.

Tabela 1 – Sobrevoou do drone em São José dos Campos/SP, Brasil.

Variable	Source	Type
Visible light images	DJI M30T	Raster
Infrared images	DJI M30T	Raster
Temperature	Embedded system	Vector
Humidity	Embedded system	Vector
VARI	Derived from images	Raster
vNDVI	Derived from images	Raster
People detection	Derived from images (AI/ML)	Vector

Fonte: O autor (2025)

Um resumo dos dados coletados e derivados durante os voos do drone é apresentado na Tabela 1. Ressalta-se que os índices de vegetação são cálculos matemáticos aplicados às imagens para estimar propriedades da vegetação, como biomassa, conteúdo de clorofila e cobertura do dossel. Esses índices são ferramentas essenciais para monitorar a saúde da vegetação, mudanças na cobertura do solo e produtividade agrícola. No sistema proposto, emprega-se dois índices: IVRA (Índice Visível Resistente à Atmosfera) e vNDVI, derivados das imagens RGB capturadas pelo drone.

Os dados de detecção de pessoas também foram derivados das imagens, utilizando algoritmos de IA/ML para identificar e localizar pessoas nas imagens.

Além da aquisição de dados reais, utilizou-se simulações realistas para ampliar nossa capacidade de capturar dados em um conjunto diversificado de situações e contextos, bem como em grandes quantidades. As capacidades de aumento de dados proporcionadas pelas simulações desempenharam um papel crucial no treinamento dos modelos de ML, bem como nos testes e validações do sistema sob diversas condições.

3.7 Transformação de Dados

Técnicas de IA foram empregadas em diversos aspectos deste projeto, incluindo a transformação de dados *raster* para vetorial e tarefas de regressão espacial. Técnicas de DL e ML foram utilizadas para abordar essas tarefas. A seleção e otimização desses modelos são realizadas com base no contexto em que são aplicados.

Duas técnicas de IA foram utilizadas para a transformação de dados *raster* para vetorial. Parte dos dados coletados por drones consiste em imagens *raster*, sendo em nossos experimentos imagens de visão aérea no espectro visível e infravermelho próximo. Essas imagens precisam ser processadas para extrair informações relevantes ampliadas, como índices de vegetação e a presença de pessoas.

Primeiramente, para a extração de índices de vegetação, índices como VARI e NDVI podem ser calculados diretamente a partir das imagens.

Em segundo lugar, a presença ou proximidade de pessoas na área também é um aspecto importante para o risco de incêndios (VILAR et al., 2021). Para detectar pessoas nas imagens, um modelo de detecção YOLO (BOCHKOVSKIY; WANG; LIAO, 2020). Foi ajustado em um conjunto de dados contendo imagens de visão aérea de pessoas. O YOLO é um sistema de detecção de objetos em tempo real que pode detectar múltiplos objetos em uma única imagem usando uma combinação de métodos de *clusterização*, aprendizado profundo e regressão. O *fine-tuning* envolve o treinamento de um modelo pré-treinado, geralmente genérico, para uma tarefa mais específica, neste caso, a detecção de pessoas a partir de uma visão aérea ou angular. O ajuste fino é geralmente realizado com conjuntos de dados menores, em menos tempo e com uma taxa de aprendizado reduzida.

Para o processo de *fine-tuning*, selecionou-se um conjunto de dados contendo imagens de visão aérea de pessoas e o ampliou-se com dados gerados a partir de simulações foto-realistas. No modelo proposto foi o YOLOv4 (BOCHKOVSKIY; WANG; LIAO, 2020), pré-treinado no conjunto de dados COCO. Os detalhes do ajuste fino, como a ampliação do conjunto de dados e os ajustes de hiperparâmetros, são determinados pelo implementador com base em suas necessidades e restrições. No caso, o *fine-tuning* resultou em um modelo que alcançou uma precisão média (mAP) de 90%, com um limite de interseção sobre união (IoU) de 0,5, sendo altamente adequado para nossa tarefa.

3.8 Simulação e Testes no mundo real

A simulação de cenários envolvendo aeronaves autônomas tem evoluído junto com a expansão do uso civil e militar dessas aeronaves. No entanto, demonstrar a viabilidade dessas propostas pode depender de simulações realistas que ajudem a identificar obstáculos potenciais

ainda não claros. Desenvolver novas soluções sem essas ferramentas de simulação é uma tarefa praticamente inviável, dado a complexidade dos cenários (MAIRAJ; BABA; JAVAID, 2019).

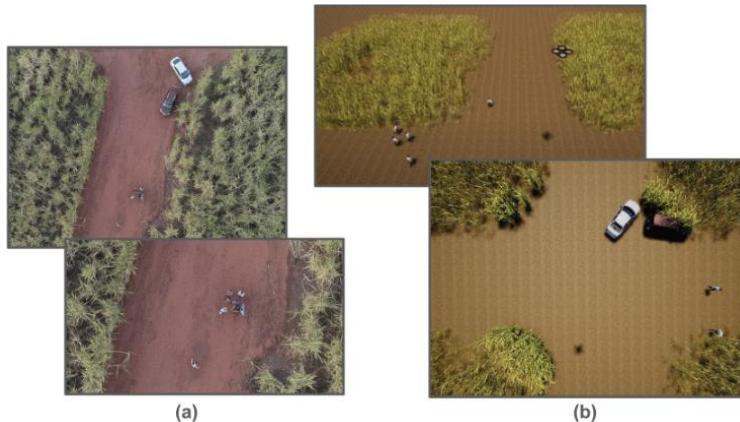
O módulo de simulação é um componente crítico de nossa estrutura para previsão de riscos de desastres, permitindo a validação e verificação do sistema em condições controladas que imitam de forma precisa cenários do mundo real. Este módulo utiliza o Unreal Engine 5 para criar ambientes 3D foto realistas e se integra com o AirSim da Microsoft para simular operações de UAV com alta fidelidade.

A criação de cenários 3D dentro do Unreal Engine 5 é um processo meticuloso que envolve o design manual do ambiente para refletir as condições do mundo real da forma mais precisa possível. Apesar de ser um processo manual, os cenários são informados por dados reais coletados de voos de UAV e diversos sensores, garantindo que condições climáticas, posicionamento de objetos e outros fatores ambientais sejam representados de forma precisa. As capacidades avançadas de renderização do Unreal Engine 5 permitem a criação de mundos virtuais altamente detalhados e imersivos, essenciais para uma simulação realista.

A plataforma de código aberto AirSim (SHAH et al., 2018), desenvolvida pela Microsoft, é integrada à nossa estrutura de simulação para fornecer simulações visuais e físicas realistas das operações de UAV. Esta integração envolve configurar o ambiente virtual no Unreal Engine 5 e ajustar o AirSim para interagir de forma contínua com esse ambiente. O AirSim suporta diversos modelos de UAVs e simula dinâmicas complexas de voo, altitude, gravidade, GPS, vento e interações físicas, que são críticas para a criação de uma simulação funcional e realista.

Para demonstrar e validar o ambiente simulado, foi definida duas tarefas principais para os UAVs simulados: (i) monitorar uma área de interesse por meio de um caminho pré-definido e (ii) detectar indivíduos dentro da área de interesse. Essas tarefas são projetadas para serem independentes do cenário, o que significa que podem ser replicadas em diferentes ambientes simulados à medida que são desenvolvidos. Inicialmente, dados simulados foram coletados em cenários personalizados para testar e aprimorar o módulo de simulação e os processos de fluxo de dados. Essas tarefas fornecem uma base robusta para avaliar as capacidades e o desempenho do sistema em diferentes condições. Para o cenário de detecção de pessoas, utilizamos a missão de voo especificada com o drone real obtido para o projeto como inspiração. Está ilustrado na Figura 4, em (a), as imagens reais capturadas com o drone e faz um contraste com (b), mostrando as imagens do cenário construído no Unreal e uma visão do drone simulado.

Figura 4 – (a) Imagem de drone do mundo real, (b) cenário simulado



Fonte: O autor (2025)

A tarefa de monitoramento envolve o UAV seguindo um caminho pré-definido dentro do ambiente simulado, coletando dados através de seus sensores embarcados. Esses dados incluem imagens de alta resolução, variáveis ambientais como temperatura e umidade, e informações de detecção de objetos. O objetivo é replicar as operações reais do UAV da forma mais precisa possível, garantindo que os dados coletados na simulação sejam representativos dos dados reais de voo. Essa abordagem permite testar e validar completamente das capacidades de aquisição e processamento de dados do sistema.

A tarefa de detecção foca no UAV identificando de forma autônoma indivíduos ou objetos dentro da área de interesse. Essa capacidade é crucial para aplicações como busca e resgate ou vigilância de segurança. O UAV utiliza algoritmos avançados de IA e técnicas de fusão de sensores para detectar e analisar objetos dentro do ambiente. Essa tarefa testa a capacidade do sistema de processar e interpretar dados complexos, fornecendo insights valiosos sobre sua eficácia operacional e áreas potenciais para melhorias.

O módulo de simulação desempenha um papel fundamental no framework de previsão de riscos de desastres, fornecendo um ambiente realista e controlado para testar e validar o sistema. Ao integrar o Unreal Engine 5 e o AirSim, criamos uma plataforma de simulação sofisticada e imersiva que aprimora a precisão e confiabilidade das operações do UAV na gestão de desastres. Essa abordagem abrangente garante que todos os aspectos da aquisição de dados, processamento e implantação de modelos de IA sejam completamente testados e validados, contribuindo, em última instância, para uma previsão e gestão de riscos de desastres mais eficazes.

4 ANÁLISE E CONCLUSÃO

Para analisar o ambiente simulado, duas tarefas foram definidas para serem realizadas por meio de um drone simulado:

1. Monitoramento da área de interesse por meio de um caminho pré-definido;
2. Detecção de pessoas na área de interesse.

Na primeira tarefa, o monitoramento seguiu um caminho quadrangular começando pelos quatro pontos da área de interesse. O drone simulado navegava em linha reta entre esses pontos. Para a segunda tarefa, o drone simulado posicionava-se no centro dos quatro pontos da área de interesse.

As tarefas definidas são agnósticas e independentes do cenário, permitindo que sejam repetidas conforme outros cenários sejam adicionados.

O ambiente simulado permite a captura de imagens da câmera simulada do drone, incluindo imagens de perspectiva panorâmica, e a criação de conjuntos de dados com associações de “verdade de solo” para cada objeto de interesse, neste caso, pessoas. Uma câmera foi especialmente posicionada para a simulação gerar dados de um ângulo superior ou aéreo (perpendicular ao solo), análogo ao que seria encontrado no drone real.

Esta ilustrado na Figura 5(a) a detecção de pessoas em um cenário simulado. Isso inclui a rotulagem precisa de indivíduos dentro do ambiente simulado, o que é crucial para treinar e validar o modelo de detecção. A Figura 5(b) mostra os resultados do YOLOv3 especializado aplicado a dados do mundo real capturados pelo drone M30T. O modelo ajustado exibe capacidades eficazes de detecção em condições reais, sugerindo o desempenho prospectivo do sistema em aplicações práticas.

A detecção de pessoas consolida o índice de pessoas na área de interesse, servindo como uma métrica de risco. Áreas urbanas com alto movimento possuem maior risco. A flexibilidade e eficiência deste sistema em detectar indivíduos em diferentes ambientes ressaltam seu potencial para aprimorar a conscientização situacional e a avaliação de riscos.

Figura 5 – (a) Detecção mundo simulado, (b) Detecção mundo real



Fonte: O autor (2025)

A implementação do sistema proposto é prevista para trazer benefícios substanciais nos âmbitos econômico, ambiental, social e tecnológico.

A integração de voos não tripulados pode reduzir significativamente os custos operacionais associados ao monitoramento e à gestão de incêndios florestais. A automação dos processos de coleta e análise de dados não apenas diminui a necessidade de mão de obra, mas também aumenta a eficiência das operações de vigilância. Além disso, os benefícios econômicos indiretos, provenientes da melhoria na detecção e resposta a incêndios, podem reduzir os custos relacionados a danos materiais e perdas de recursos.

Mesmo com dados escassos para certas regiões, o uso de métodos de IA permitiu interpolar pontos de dados ausentes e fornecer cobertura abrangente.

A simulação mostrou-se promissora para representar índices de vegetação em cenários simulados com diferentes tipos de vegetação. Simulações realistas também podem auxiliar no treinamento de modelos de ML.

O modelo de representação e armazenamento de dados lidou eficazmente com dados de missões reais de voos de drones, bem como com conjuntos de dados de voos simulados. O sistema demonstrou sua capacidade ao correlacionar dados de vários sensores (umidade, temperatura) com imagens aéreas das regiões de interesse e detectar a presença de pessoas nessas áreas.

Apesar dos sucessos, enfrentou-se vários desafios e limitações que oferecem insights valiosos para trabalhos futuros:

- Cenários de simulação foram criados com base em dados históricos de missões de voo ou características esperadas de voos reais. Automatizar a construção desses cenários pode melhorar a eficiência. Investigar a criação de gêmeos digitais para esses cenários pode fornecer soluções mais robustas e paralelizáveis.

- Não foi simulado múltiplos drones em uma única execução. Implementar isso com mais processamento paralelo poderia melhorar significativamente a eficiência. Além disso, o uso de gêmeos digitais para drones especializados em várias tarefas de voo merece mais exploração.

- Introduzir um enxame de drones, ou mesmo apenas dois, traz implicações para a transformação de dados e a infraestrutura de comunicação. Isso pode aumentar a complexidade e requer consideração cuidadosa e mais estudos.

- Investigar a viabilidade e os benefícios do processamento em borda para transformação de dados, visando reduzir a latência e aumentar a eficiência do processamento. A comunicação em tempo real com os drones também pode ser benéfica em missões sensíveis ao tempo e na tomada de decisões.

- Desenvolver ferramentas automatizadas para construção de cenários, potencialmente aproveitando a tecnologia de gêmeos digitais, para criar ambientes de simulação mais dinâmicos e realistas.

- A implementação de simulações de múltiplos drones em paralelo, incluindo o desenvolvimento de gêmeos digitais especializados para diferentes tarefas de voo, a fim de aprimorar o planejamento e a execução de missões.

- Avaliar o impacto de enxames de drones na infraestrutura de processamento e comunicação de dados, para compreender melhor e gerenciar o aumento da complexidade. Além disso, o uso da incerteza das previsões para guiar o caminho dos drones e otimizar o processo de coleta de dados é uma direção promissora de pesquisa.

Conclusão

O sistema proposto neste trabalho de conclusão de curso utiliza tecnologia de IA e drones para aprimorar o monitoramento de incêndios florestais e a avaliação de riscos. Integrando dados de vários sensores e aplicando algoritmos sofisticados de IA, o sistema fornece previsões precisas e visualizações do risco de incêndios florestais.

REVISÃO BIBLIOGRÁFICA

BARROS, A; PEREIRA, J. “Wildfire selectivity for land cover type: Does size matter?” PLOS ONE, vol. 9, no. 1, pp. 1–10, 2014

BOCHKOVSKIY, A; WANG, C; LIAO, H. “Yolov4: Optimal speed and accuracy of object detection,” arXiv preprint arXiv:2004.10934, 2020.

Disponível em: <<https://arxiv.org/abs/2004.10934>>

Acesso em: 21/07/2024.

BOROUJENI, S; *et al.* “A comprehensive survey of research towards ai-enabled unmanned aerial systems in pre-, active-, and post-wildfire management,” Inf. Fusion, vol. 108, p. 102369, 2024.

C. A. M. S. “2023: A year of intense global wildfire activity”, disponível em: <<https://atmosphere.copernicus.eu/2023-year-intense-global-wildfire-activity>>

Acesso em: 21/07/2024.

COOGAN, S; *et al.* “Scientists’ warning on wildfire — a canadian perspective,” Can. J. For. Res., vol. 49, no. 9, pp. 1015–1023, 2019.

COSTA, L; NUNES, L; AMPATZIDIS, Y. “Anewvisible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms,” Computers and Electronics in Agriculture, vol. 172, p. 105334, 2020.

CRESSIE, N. Statistics for spatial data. John Wiley & Sons, 2015.

DESHMUKH, A; *et al.* “Satellite image segmentation for forest fire risk detection using gaussian mixture models,” in 2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAAIC), 2023, pp. 806– 811.

FOTHERINGHAM, A; BRUNSDON, C; CHARLTON, M. Geographically Weighted Regression: The Analysis of Spatially Varying Relationships. Wiley, 2003.

Disponível em: <<https://books.google.com.br/books?id=9DZgV1vXOuMC>>

Acesso em: 21/07/2024.

GARCIA, L; et al. “Record-breaking wildfires in the world’s largest continuous tropical wetland: Integrative fire management is urgently needed for both biodiversity and humans,” J. Environ. Manage., vol. 293, p. 112870, 2021.

GEIRINHAS, J; et al. “**Combined large-scale tropical and subtropical forcing on the severe 2019–2022 drought in south america**”, npj Climate and Atmospheric Science, vol. 6, no. 1, p. 185, 2023.

GRANT,S ; et al. “**Long-term health effects of wildfire exposure: a scoping review**,” J. Clim. Change Health, vol. 6, p. 100110, 2022.

GRIFFITH, D. “Spatially autoregressive models,” in International Encyclopedia of Human Geography, R. Kitchin and N. Thrift, Eds. Oxford: Elsevier, 2009, pp. 396–402.

FEDERAL, S.P. “Plano de ação para o manejo integrado do fogo no bioma pantanal”.

Disponível em: <https://www.gov.br/ibama/pt-br/assuntos/fiscalizacao-e-protecao-ambiental/incendios-florestais/arquivos/20230620_Plano_acao_Pantanal.pdf>

Acesso em: 21/07/2024.

HUNT, E; et al. “A visible band index for remote sensing leaf chlorophyll content at the canopy scale,” International Journal of Applied Earth Observation and Geoinformation, vol. 21, pp. 103–112, 2013.

HUETE, A; et al. “Overview of the radiometric and biophysical performance of the modis vegetation indices,” Remote Sensing of Environment, vol. 83, no. 1, pp. 195–213, 2002.

KABIR, M; et al. “Wildfire prediction in the united states using time series forecasting models”. Annals of Emerging Technologies in Computing (AETiC), vol. 8, no. 2, pp. 32–42, 2024.

KAMAL, R. Microcontrollers: Architecture, programming, interfacing and system design. Pearson Education India, 2011.

KANAND, T; *et al.* “Wildfire detection and disaster monitoring system using uas and sensor fusion technologies,” Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., vol. XLIII-B3-2020, pp. 1671–1675, 2020.

LÁZARO, W; *et al.* “**Climate change reflected in one of the largest wetlands in the world: an overview of the northern pantanal water regime**”, Acta Limnol. Bras., vol. 32, p. e104, 2020.

LIBONATI, R; *et al.* “**Assessing the role of compound drought and heatwave events on unprecedented 2020 wildfires in the pantanal**”, Environ. Res. Lett., vol. 17, no. 1, p. 015005, 2022.

MAIRAJ, A; BABA, A; JAVAID, A. “Application specific drone simulators: Recent advances and challenges,” Simul. Model. Pract. Theory, vol. 94, pp. 100–117, 2019.

MARENGO, J; ALVES, L; TORRES R. “Regional climate change scenarios in the brazilian pantanal watershed,” Clim. Res., vol. 68, no. 2-3, pp. 201–213, 2016.

MARQUES, J; *et al.* “**Fires dynamics in the pantanal: Impacts of anthropogenic activities and climate change**”. J. Environ. Manage., vol. 299, p. 113586, 2021.

MILLER, H. “Tobler’s first law and spatial analysis,” Annals of the association of American geographers, vol. 94, no. 2, pp. 284–289, 2004.

RASHID, M; *et al.* “Compdron: towards integrated computational model and social drone based wildfire monitoring,” in 2020 16th international conference on distributed computing in sensor systems (DCOSS). IEEE, 2020, pp. 43–50.

RIBEIRO, A; *et al.* “A compound event-oriented framework to tropical fire risk assessment in a changing climate,” Environ. Res. Lett., vol. 17, no. 6, p. 065015, 2022.

ROUSE, J; *et al.* “Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation,” NASA/GSFC Type III Final Report, 1974.

Disponível em:

<<https://ntrs.nasa.gov/api/citations/19750020419/downloads/19750020419.pdf>>

Acesso em: 21/07/2024.

RUBÍ, J; GONDIM, P. “**A performance comparison of machine learning models for wildfire occurrence risk prediction in the brazilian federal district region,**” Environ. Syst. Decis., vol. 44, no. 2, pp. 351–368, 2024.

SHAH, S; *et al.* “Airsim: High-fidelity visual and physical simulation for autonomous vehicles,” in Field and Service Robotics, M. Hutter and R. Siegwart, Eds. Cham: Springer International Publishing, 2018, pp. 621–635.

SHAMTA, I; DEMIR, B. “Development of a deep learning-based surveillance system for forest fire detection and monitoring using UAV,” PLOS ONE, vol. 19, no. 3, p. e0299058, 2024.

SILVA, P; *et al.* “Heatwaves and fire in pantanal: Historical and future perspectives from cordex-core,” J. Environ. Manage., vol. 323, p. 116193, 2022.

SYPHARD, A; *et al.* “Mapping future fire probability under climate change: Does vegetation matter?” PLOS ONE, vol. 13, no. 8, pp. 1–23, 2018.

U. E. P. (UNEP). GRID-Arendal, “Spreading like wildfire: The rising threat of extraordinary landscape fires”. Disponível em: <<https://www.unep.org/resources/report/spreading-wildfire-rising-threat-extraordinary-landscape-fires>>

Acesso em: 21/07/2024.

VILAR, S; *et al.* “Modelling wildfire occurrence at regional scale from land use/cover and climate change scenarios,” Environmental Modelling & Software, vol. 145, p. 105200, 2021

XU, Z; LI, J; XU, L. “Wildfire risk prediction:Areview,” arXiv preprint arXiv:2405.01607, 2024.

Zhai, J; *et al.* “Wildfire susceptibility of land use and topographic features in the western united states: Implications for the landscape management,” *Forests*, vol. 14, no. 4, 2023.