



INSTITUTO FEDERAL
Piauí



**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
MESTRADO PROFISSIONAL EM ANÁLISE E PLANEJAMENTO ESPACIAL**

LUIZ EDUARDO ARAUJO SILVA

**APLICAÇÃO DE ÁLGEBRA DE MAPAS E ANÁLISE MULTICRITÉRIO NO
GOOGLE EARTH ENGINE PARA MAPEAR O RISCO DE INCÊNDIOS EM
URUÇUI-PI**

TERESINA – PI

2026

LUIZ EDUARDO ARAUJO SILVA

**APLICAÇÃO DE ÁLGEBRA DE MAPAS E ANÁLISE MULTICRITÉRIO NO
GOOGLE EARTH ENGINE PARA MAPEAR O RISCO DE INCÊNDIOS EM
URUÇUI-PI**

Relatório Final apresentado ao Programa de Pós-Graduação em Análise e Planejamento Espacial do Instituto Federal do Piauí, como parte integrante dos requisitos para a obtenção título de Mestre em Análise e Planejamento Espacial.

Linha de Pesquisa: Análise Ambiental.

Orientadora: Prof. Dra. Sammya Vanessa Chaves Vieira

Coorientador: Prof. Dr. Edilson Lívio Neves da Costa Carneiro

TERESINA – PI

2026

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Silva, Luiz Eduardo Araújo

S586a Aplicação de álgebra de mapas e análise multicritério no google earth engine para mapiar o risco de incêndios em Uruçui - Pi / Luiz Eduardo Araújo Silva. - 2026.

123 f.: il. color.

Dissertação (Mestrado Profissional em Análise e Planejamento Espacial) - Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Teresina Central, 2026.

Orientadora : Profa Dr. Sammya Vanessa Chaves Vieira.

Coorientador : Prof Dr. Eduilson Lívio Neves da Costa Carneiro.

1. Risco ambiental. 2. AHP. 3. Focos de calor. I. Título.

CDD - 910

LUIZ EDUARDO ARAUJO SILVA

**APLICAÇÃO DE ÁLGEBRA DE MAPAS E ANÁLISE MULTICRITÉRIO NO
GOOGLE EARTH ENGINE PARA MAPEAR O RISCO DE INCÊNDIOS EM
URUÇUI-PI**

Relatório Final apresentado ao Programa de Pós-Graduação em Análise e Planejamento Espacial do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, como parte integrante dos requisitos para a obtenção título de Mestre em Análise e Planejamento Espacial.

Aprovado em: 15/04/2026

BANCA EXAMINADORA

Profa. Dra. Sammya Vanessa Chaves Vieira (Orientadora)
Instituto Federal de Educação do Piauí (IFPI)

Prof. Dr. Eduilson Lívio Neves da Costa Carneiro (Coorientador)
Instituto Federal de Educação do Piauí (IFPI)

Profa. Dra. Dinameres Aparecida Antunes
Universidade Federal do Paraná (UFPR)

Prof. Dr. Francílio de Amorim dos Santos
Instituto Federal do Piauí (IFPI)

Dedico este trabalho a minha Tia Lúcia (*in
memoriam*).

AGRADECIMENTOS

Primeiramente, agradeço a Deus, por todas as vezes em que rezei e pedi discernimento, sendo atendido desde o processo seletivo do mestrado, passando por todas as provas e trabalhos entregues, até a conclusão desta pesquisa. Toda honra seja dada a Ti.

À minha tia Lúcia (*in memoriam*), que sempre foi a luz a me guiar em cada linha aqui escrita. Foi minha mãe, minha maior apoiadora, e acreditou em todos os meus sonhos. Obrigado por tanto. Amo você.

Às minhas tias Sílvia e Orlene, que, ao longo da vida, sempre estiveram entre as primeiras a me aplaudir e a me apoiar. Não chegaria até aqui se não fosse por vocês. À minha irmã, Maria Clara, pelo apoio e por estar sempre ao meu lado quando precisei.

Aos meus amigos, por todas as vezes em que precisei desabafar ou falar do mesmo assunto diversas vezes, e vocês estiveram dispostos a ouvir. Tenham certeza de que me senti acolhido em todos esses momentos. Aos meus colegas de turma do mestrado, por todas as conversas, risadas, dicas e momentos compartilhados; vocês tornaram as aulas mais leves e deixaram lembranças que levarei comigo com muito carinho.

À minha orientadora, Professora Dra. Sammya Chaves, por me mostrar os caminhos para a construção e a conclusão deste trabalho, mas, sobretudo, por ser humana, empática, sensível e amiga, compreendendo minha rotina de trabalho e estudos. Todos os encontros e viagens a congressos são lembranças que levarei comigo com muito carinho. Ao meu coorientador, Professor Dr. Eduilson Carneiro, por toda a disponibilidade em me ajudar, orientar e mostrar o melhor caminho. Sou muito grato.

Ao Instituto Federal do Piauí, por me proporcionar a realização desse sonho, em especial aos professores do MAPEPROF. Amei cada aula e tenho carinho por todos vocês, que fazem parte da minha formação acadêmica. Levo comigo cada aprendizado. Meu muito obrigado.

“Direi do Senhor: Ele é o meu Deus, o
meu refúgio, a minha fortaleza, e nele
confiarei”
Bíblia Sagrada (Salmo 91).

RESUMO

Os incêndios florestais têm se intensificado no Brasil e configuram um importante problema ambiental em áreas de expansão agropecuária, como o município de Uruçuí, no sul do Piauí. Nesse contexto, este trabalho teve como objetivo identificar áreas com risco de incêndios por meio da aplicação de Análise Multicritério e Álgebra de Mapas no *Google Earth Engine*. Especificamente, buscou-se selecionar e ponderar variáveis ambientais por meio do Processo de Análise Hierárquica (AHP), integrar essas variáveis em um índice contínuo de risco e validar sua coerência espacial com focos de calor detectados pelo sensor VIIRS no ano de 2024. O modelo foi estruturado com base nas variáveis precipitação, temperatura de superfície, índice de vegetação por diferença normalizada (NDVI), declividade, altitude e orientação das encostas, as quais foram normalizadas e combinadas em ambiente JavaScript no *Google Earth Engine*, resultando em um índice contínuo posteriormente classificado em quartis. A validação incluiu a geração de 366 mapas diários e a deduplicação espaço-temporal da base observada, reduzindo-a de 37.620 registros brutos para 1.417 focos deduplicados. Os resultados mostraram que 77,56% dos focos se concentraram nos quartis superiores do índice, correspondentes às faixas de maior risco, com destaque para o quartil mais elevado, que reuniu 25,83% dos focos em 21,47% da área acumulada, alcançando razão de eficiência de 1,20. Os meses de agosto, setembro e outubro concentraram 76,2% das ocorrências, evidenciando a sazonalidade do fenômeno e a relevância dos mapas-síntese mensais para a interpretação espacial dos padrões de risco. Conclui-se que o modelo apresentou melhor desempenho como ferramenta de hierarquização espacial do risco e de apoio à priorização territorial de ações preventivas do que como classificador rígido de ocorrência e não ocorrência de fogo. Como produto técnico, foi desenvolvido um script no *Google Earth Engine*, com potencial de aplicação prática no monitoramento e na gestão ambiental municipal.

Palavras-chaves: risco ambiental; AHP; focos de calor.

ABSTRACT

Forest fires have intensified in Brazil and constitute a major environmental issue in areas of agricultural expansion, such as the municipality of Uruçuí, in southern Piauí. In this context, this study aimed to identify fire-risk areas through the application of Multicriteria Analysis and Map Algebra in Google Earth Engine. Specifically, the study sought to select and weight environmental variables using the Analytic Hierarchy Process (AHP), integrate these variables into a continuous risk index, and validate its spatial coherence with hotspots detected by the VIIRS sensor in 2024. The model was structured based on the variables precipitation, land surface temperature, Normalized Difference Vegetation Index (NDVI), slope, altitude, and aspect, which were normalized and combined in a JavaScript environment within Google Earth Engine, resulting in a continuous index that was subsequently classified into quartiles. Validation included the generation of 366 daily maps and the spatiotemporal deduplication of the observed dataset, reducing it from 37,620 raw records to 1,417 deduplicated hotspots. The results showed that 77.56% of the hotspots were concentrated in the upper quartiles of the index, corresponding to the highest-risk ranges, with emphasis on the highest quartile, which accounted for 25.83% of the hotspots within 21.47% of the accumulated area, reaching an efficiency ratio of 1.20. The months of August, September, and October concentrated 76.2% of the occurrences, highlighting the seasonality of the phenomenon and the relevance of the monthly synthesis maps for the spatial interpretation of risk patterns. It is concluded that the model performed better as a tool for spatial risk ranking and for supporting the territorial prioritization of preventive actions than as a strict classifier of fire occurrence and non-occurrence. As a technical product, a script was developed in Google Earth Engine, with potential practical application in municipal environmental monitoring and management.

Keywords: environmental risk; AHP; hotspots.

LISTA DE TABELAS

Tabela 1 – Valores de Índice Aleatório.....	40
Tabela 2 – Matriz de Comparação de Julgamentos e Pesos	54
Tabela 3 – Distribuição anual dos focos, área acumulada e razão de eficiência por classe quartílica do índice de risco em Uruçuí (2024).....	65

LISTA DE QUADROS

Quadro 1 – Escala Fundamental de Saaty.	38
Quadro 2 – Estrutura de uma matriz quadrada (n x n) de critérios.	39
Quadro 3 – Classificação da Orientação das Encostas.....	53
Quadro 4 – Classes temáticas do índice de risco.....	56
Quadro 5 – Estrutura Operacional do Script.....	74

LISTA DE FIGURAS

Figura 1 – Mapa de Localização de Uruçuí – PI.....	44
Figura 2 – Quartis do Índice de Risco (diário)	58
Figura 3 - Número de focos brutos e focos deduplicados em 2024.....	62
Figura 4 – Mapas-síntese da frequência de permanência em Q3+Q4 e distribuição dos focos VIIRS em agosto, setembro e outubro	69
Figura 5 – Detalhamento espacial dos focos em relação a padrões de ocupação da paisagem, no mês de agosto de 2024.	71
Figura 6 – Detalhamento espacial dos focos em relação a padrões de ocupação da paisagem, no mês de setembro de 2024.	72
Figura 7 – Detalhamento espacial dos focos em relação a padrões de ocupação da paisagem, no mês de outubro de 2024.	72

LISTA DE GRÁFICO

Gráfico 1 – Número de Focos de Calor registrados em Uruçuí – PI segundo o INPE.	24
Gráfico 2 – Distribuição mensal dos focos em Uruçuí – PI (2024)	62

Gráfico 3 – Focos de calor VIIRS por classe de risco (2024).....	63
Gráfico 4 – Distribuição da área (km².dia) por classe de risco em 2024.	64
Gráfico 5 – Comparação entre o percentual de focos e o percentual de área acumulada por classes em Uruçuí (2024).....	66
Gráfico 6 – Distribuição dos focos por classe quartílica (agosto, setembro e outubro)	67
Gráfico 7 – Distribuição dos focos e da área por faixa de recorrência mensal (Q3+Q4)	70

LISTA DE ABREVIATURAS E SIGLAS

GEE	Google Earth Engine
RAF	Relatório Anual do Fogo
INPE	Instituto Nacional de Pesquisas Espaciais
MATOPIBA	Maranhão, Tocantins, Piauí e Bahia
LANDSAT	Land Satellite Program
MODIS	Moderate Resolution Imaging Spectroradiometer
LST	Land Surface Temperature.
NOAA AVHRR	National Oceanic and Atmospheric Administration - Advanced Very High Resolution Radiometer
SENTINEL-1	Sentinel-1 Synthetic Aperture Radar
SENTINEL-2	Sentinel-2 Multispectral Instrument
SENTINEL-3	Sentinel-3 Ocean and Land Colour Instrument
SENTINEL-5	Sentinel-5 Precursor TROPOspheric Monitoring Instrument
ALOS	Advanced Land Observing Satellite
EVI	Índice de Vegetação Aprimorado
NDVI	Índice de Vegetação por Diferença Normalizada
GIS	Sistema de Informação Geográfica
NBR	Índice de Queima Normalizada
AHP	Processo de Análise Hierárquica
IC	Índice de Consistência
RI	Índice Aleatório
RC	Razão de Consistência
IBGE	Instituto Brasileiro de Geografia e Estatística

VIIRS	Visible Infrared Imaging Radiometer Suite
JPSS	Joint Polar Satellite System-1
FRP	Potência Radiativa do Foco
CHIRPS	Climate Hazards Center InfraRed Precipitation with Station Data
MDE	Modelo Digital de Elevação
SRTM	Shuttle Radar Topography Mission

SUMÁRIO

1	INTRODUÇÃO	16
2	OBJETIVOS	17
2.1	OBJETIVO GERAL.....	17
2.2	OBJETIVOS ESPECÍFICOS	17
3	FUNDAMENTAÇÃO TEÓRICA	18
3.1	INCÊNDIOS FLORESTAIS.....	18
3.2	INCÊNDIOS FLORESTAIS NO BRASIL	21
3.3	<i>GOOGLE EARTH ENGINE (GEE)</i>	25
3.4	FATORES DE RISCO.....	27
3.4.1	Precipitação	27
3.4.2	Temperatura	29
3.4.3	Cobertura Vegetal	31
3.4.4	Declividade	32
3.4.5	Altimetria	33
3.4.6	Orientação das Encostas (Aspecto)	34
3.5	ANÁLISE MULTICRITÉRIO.....	36
3.6	PROCESSO DE ANÁLISE HIERÁRQUICA (AHP)	37
3.7	ÁLGEBRA DE MAPAS	42
4	METODOLOGIA	43
4.1	DELIMITAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO	43
4.2	SELEÇÃO DOS DADOS AMBIENTAIS	45
4.3	PROCESSAMENTO DOS DADOS	46
4.3.1	Temperatura	48
4.3.2	Precipitação	49
4.3.3	Cobertura Vegetal (via NDVI)	50
4.3.4	Declividade	51

4.3.5	Altitude	52
4.3.6	Orientação das Encostas (aspecto)	53
4.4	PROCESSO DE ANÁLISE HIERÁRQUICA	54
4.5	IMPLEMENTAÇÃO DO PRODUTO TÉCNICO.....	55
4.6	VALIDAÇÃO DO MÉTODO	57
4.6.1	Focos de calor VIIRS	59
4.6.2	Mapas-sínteses dos meses críticos	60
5	RESULTADOS E DISCUSSÃO	61
5.1	CONSOLIDAÇÃO DA BASE DE VALIDAÇÃO	61
5.2	MAPAS-SÍNTESES DOS MESES CRÍTICOS	67
5.3	PRODUTO TÉCNICO-TECNOLÓGICO DERIVADO DA PESQUISA.....	73
5.3.1	Descrição do script e fluxo operacional	73
5.3.2	Potencial de aplicação prática	76
6	CONSIDERAÇÕES FINAIS	77
	REFERÊNCIAS	80

1 INTRODUÇÃO

As florestas desempenham um papel essencial na preservação dos ecossistemas globais e no bem-estar da sociedade. Elas são fundamentais para a manutenção da biodiversidade, a regulação do clima e o fornecimento de recursos naturais, impactando diretamente nos âmbitos social, ambiental e econômico. No entanto, o aumento dos incêndios florestais, tanto no Brasil quanto no mundo, figura como um dos problemas ambientais mais graves da atualidade.

Esse fenômeno tem se tornado cada vez mais frequente devido à interação entre fatores humanos e ambientais. Embora a maioria dos incêndios florestais tenha origem em atividades humanas — já que o uso do fogo acompanha a história das sociedades —, são elementos como as condições climáticas e o tipo de vegetação que influenciam diretamente a intensidade e a propagação desses eventos destrutivos.

Para combater os efeitos negativos do fogo, é essencial o desenvolvimento de metodologias, planos de ação e políticas públicas voltados para a prevenção. A compreensão dos componentes ambientais que influenciam a ocorrência e propagação dos incêndios é crucial para identificar as áreas mais suscetíveis e, assim, adotar medidas de mitigação mais eficazes.

Fatores climáticos estão fortemente relacionados à ocorrência de incêndios florestais. Condições como baixos índices de precipitação, má distribuição das chuvas, baixa umidade relativa do ar e o aumento das temperaturas médias favorecem a propagação do fogo, tornando o controle desses eventos ainda mais desafiador. Além disso, fatores antrópicos, como as alterações na cobertura das terras, especialmente a redução da vegetação nativa, permanecem como importantes catalisadores desses incêndios.

Nos últimos anos, diversos pesquisadores têm combinados variáveis ambientais e sociais com o intuito de mapear áreas suscetíveis a incêndios. Essa abordagem, aliada aos avanços nas técnicas de geoprocessamento, tem impulsionado o uso de plataformas como o *Google Earth Engine* (GEE), tornando-as cada vez mais eficazes para análises espaciais e modelagens preditivas.

Apesar dos avanços, não há um conjunto universal de quais variáveis devem necessariamente compor os modelos de risco de incêndios, pois a seleção depende do contexto ambiental e escala espacial/temporal. Nesse contexto, a seleção dos indicadores se mostra fundamental para garantir maior precisão e coerência na avaliação do risco de incêndios. No semiárido brasileiro, por exemplo, variáveis como temperatura, precipitação, altitude, declividade, orientação das encostas e cobertura vegetal desempenham papel central na ignição e propagação do fogo.

Diante disso, este trabalho tem como objetivo aplicar Análise Multicritério e Álgebra de Mapas para identificar áreas com risco a incêndios florestais em Uruçuí, Piauí, utilizando o *Google Earth Engine*.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Identificar áreas com risco de incêndios no município de Uruçuí, Piauí, a partir da aplicação de Análise Multicritério e Álgebra de Mapas no Google Earth Engine.

2.2 OBJETIVOS ESPECÍFICOS

- Construir um arcabouço multicritério, por meio da Análise Hierárquica do Processo (AHP) para seleção de variáveis ambientais (precipitação, temperatura de superfície, NDVI, declividade, altitude e orientação das encostas) e para definição dos pesos e sentidos de influência no risco de incêndios;
- Integrar as variáveis por Álgebra de Mapas no GEE, implementando em *JavaScript* um índice contínuo de risco e sua classificação cartográfica por quartis;
- Validar o índice com focos VIIRS (2024) por meio da Razão de Eficiência e mapas-sínteses dos meses mais críticos, avaliando a coerência espacial e a capacidade de hierarquização do índice frente às ocorrências observadas;
- Analisar e discutir os padrões espaciais identificados, destacando a influência dos fatores ambientais na ocorrência dos incêndios e discutir aplicações para a gestão (priorização territorial de prevenção e resposta), indicando limitações do método e oportunidades de aprimoramento.

- Propor como produto desse trabalho um script implementado, para automatizar a identificação de áreas com risco de incêndios florestais, disponibilizado em ambiente GitHub e como apêndice.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 INCÊNDIOS FLORESTAIS

Qualquer alteração no ambiente e em seus componentes elementares (solo, vegetação, clima, recursos hídricos) pode catalisar o desequilíbrio e comprometer a sua funcionalidade (Souza et al., 2020). Um dos eventos que desencadeia esse ônus são as queimadas e incêndios florestais, que provocam uma destruição parcial dos biomas e seus ecossistemas, e possuem potencial de causar prejuízos econômicos além da perturbação ambiental (Pivello et al., 2021).

Segundo Freire (2006), incêndio florestal refere-se à propagação descontrolada do fogo sobre áreas de vegetação natural, podendo ter origem tanto em ações humanas quanto em fenômenos naturais. Seu comportamento varia conforme as condições ambientais presentes no local atingido. Por outro lado, as queimadas consistem em práticas realizadas no meio agropecuário ou florestal, nas quais o fogo é empregado de maneira planejada e controlada, com o objetivo de auxiliar na produção. Quando devidamente autorizadas pelos órgãos ambientais competentes e executadas conforme normas específicas, essas queimadas são denominadas prescritas. Nesse contexto, o uso do fogo deixa de representar uma ameaça e passa a ser um instrumento de manejo do território, vinculado ao planejamento ambiental e à organização do uso do solo.

Desde tempos antigos, as queimadas têm sido empregadas para diversas finalidades, no início das práticas agrícolas e pastoris, houve uma exploração repetitiva e prejudicial dos recursos da biosfera, provocando uma extração desproporcional de biomassa e a prática indiscriminada e prejudicial das queimadas, que é considerada uma tradição antiga entre os agricultores para a limpeza da terra e preparação para o cultivo ou atividade pecuária (Marque e Sobrinho, 2020).

Alcantara e Fernandes (2020), apontam que o aumento do desmatamento, por exemplo, está intrinsecamente vinculado às queimadas ilegais de biomassa

promovidas por pequenos e médios produtores rurais, pois esse método ainda é considerado uma opção rápida e de custo reduzido para a preparação de terrenos destinados à agricultura.

Logo, o fogo não deve ser visto apenas como um fenômeno ecológico ou uma questão ambiental isolada, mas sim como uma relação complexa. Entender essa relação, suas diferentes formas e as maneiras pelas quais ela se modifica ao longo do tempo é essencial para promover uma gestão do risco de incêndios florestais que seja integrada e orientada para a sustentabilidade (Pyne, 2007; Tedim e Carvalho, 2013).

Ao longo dos anos, os incêndios florestais foram fortemente influenciados por causas antrópicas, ou seja, atividades humanas que aumentam tanto a frequência quanto a intensidade desses eventos. Kolanek et al. (2021) observaram que as florestas localizadas nas proximidades de áreas urbanizadas, estradas e linhas ferroviárias apresentam maior risco de ocorrência de incêndios florestais.

Abatzoglou e Williams (2016) observaram que as mudanças climáticas causadas pelas emissões humanas causaram aumento das secas dos combustíveis florestais da região oeste dos Estados Unidos nas últimas décadas, prolongando a temporada de incêndios, promovendo um ambiente mais favorável aos incêndios em todos os sistemas florestais.

Já Canadell et al. (2021) compilaram e analisaram extensas séries temporais de dados de áreas queimadas por satélites e registros terrestres, abrangendo até 90 anos de observações em florestas australianas. O estudo destacou o aumento expressivo de eventos de ‘megaincêndios’ — aqueles que ultrapassam 1 milhão de hectares queimados — após o ano 2000. Esse agravamento está associado a condições climáticas cada vez mais propícias à propagação do fogo, ao crescimento de fatores de risco relacionados à piroconvecção, como tempestades induzidas por incêndios, e à elevação nas ignições causadas por raios secos, todos fenômenos intensificados pelas mudanças climáticas de origem antrópica.

Para Mariane et al. (2016) e Ribeiro (2021) a deflagração do fogo está ligada não somente a ação humana, mas também a outros componentes ambientais, como o clima, precipitação e características físicas do relevo e da vegetação. Nesse contexto, Abatzoglou e Williams (2016), explicam que o clima exerce papel central na

ocorrência de incêndios florestais, influenciando tanto a quantidade de combustível disponível em ambientes onde ele é limitado, quanto o grau de secura desse material em regiões onde a inflamabilidade é o fator restritivo.

De forma complementar, Jones et al. (2022) apontam que os incêndios tendem a ocorrer com maior frequência em regiões com umidade intermediária, nas quais há biomassa suficiente para queimar e condições sazonais de seca que favorecem sua ignição. Por outro lado, eles são menos comuns em áreas permanentemente úmidas, onde a vegetação raramente está seca, ou em regiões excessivamente áridas, nas quais a escassez de umidade impede o acúmulo de combustível.

Já para Holden et al. (2018), a diminuição da precipitação, principalmente durante a estação de fogo, é um dos principais catalizadores para o aumento de áreas queimadas, uma vez que reduz a umidade do material combustível e prolonga os períodos secos. Essa escassez de chuvas favorece o aquecimento da superfície, aumenta a demanda evaporativa e potencializa a inflamabilidade da vegetação, criando condições mais propícias para a propagação de incêndios florestais.

Silva, Lopes e Santos (2018), por exemplo, identificaram uma relação direta entre o aumento das temperaturas da superfície do solo e a redução dos índices de precipitação com a expansão das áreas queimadas na região Amazônica brasileira entre 2001 e 2019.

De outro ângulo, Kane et al. (2015), afirmam que uma topografia complexa cria mosaicos ambientais de pequena escala que variam em precipitação, temperatura, insolação e posição da encosta. Este mosaico, por sua vez, influencia o acúmulo de combustível, a umidade e a estrutura da floresta, e por tanto, na ocorrência, propagação e severidade dos incêndios florestais.

Piao et al. (2021) observaram que uma declividade moderadamente íngreme tem um impacto considerável na ocorrência de incêndios florestais na região de Gangwon-do na Coreia, utilizando algoritmos de aprendizado de máquina. Já Estes et al. (2017) concluíram que a posição e orientação da encosta foram os mais importantes fatores topográficos que determinaram a gravidade do fogo em incêndios nas Florestas Nacionais de Klamath e Six Rivers na Califórnia, EUA.

Essa diversidade de componentes, sistematizados a partir do uso de geotecnologias, desempenha um papel essencial na identificação e mapeamento dos focos de calor, uma vez que permite a construção de informações a respeito do comportamento desses focos, além de proporcionar possíveis correlações com variáveis ambientais e antrópicas (Carneiro e Albuquerque, 2019).

3.2 INCÊNDIOS FLORESTAIS NO BRASIL

Os incêndios florestais no território brasileiro, especialmente na Amazônia, Pantanal e Cerrado, têm aumentado em frequência e intensidade nas últimas décadas, impulsionados por fatores climáticos, socioeconômicos e políticos. Esses eventos afetam profundamente a biodiversidade, o clima, a saúde humana e a estabilidade dos ecossistemas (Pivello et al., 2021).

Historicamente, no período de seca, as mídias brasileiras apresentam fortes cenas de incêndios, ecossistemas destruídos, animais e pessoas morrendo pelo fogo. Em 2004, os incêndios na Amazônia atingiram um recorde absoluto, resultando em adoção de algumas políticas de controle para uso do fogo, no qual houve uma redução significativa dos focos até meados de 2013 (Silva Junior et al., 2021). Entretanto, a partir de 2014, os índices voltaram a crescer, culminando em 2024 com 87.366 focos de incêndio detectados, o maior número do período entre 2011 e 2025 (INPE, 2025).

De acordo com o Relatório Anual do Fogo – RAF (MapBiomass, 2025), aproximadamente 24% do território brasileiro foi atingido pelo fogo pelo menos uma vez entre 1985 e 2024. Os dados recentes revelam um agravamento expressivo: entre 2023 e 2024, a área queimada no Brasil praticamente dobrou, passando de cerca de 16 milhões de hectares para mais de 30 milhões de hectares. Com isso, 2024 tornou-se o segundo ano com maior extensão queimada desde 1985, sendo superado apenas por 2007, quando foram registrados 30,7 milhões de hectares destruídos pelo fogo.

No recorte por biomas, a Amazônia respondeu por 42,4% do total queimado no país, tendo 20,8% de sua área afetada pelas chamas. O Pantanal, embora tenha representado apenas 4,5% do total nacional, foi proporcionalmente o mais devastado, com 61,8% de sua área comprometida. Já o Cerrado destacou-se como o bioma mais impactado em termos absolutos, concentrando 43,4% de toda a área queimada no

Brasil no período analisado. Esse valor equivale a 45,1% da extensão total do bioma, evidenciando sua extrema vulnerabilidade às queimadas e reforçando sua posição como um dos ecossistemas mais pressionados pelo fogo (MapBiomas, 2025).

De forma complementar, o Programa Queimadas do Instituto Nacional de Pesquisas Espaciais - INPE (2025) aponta que, até agosto de 2025, o Cerrado liderou no número de focos de incêndio detectados, com 17.590 ocorrências. Em seguida, aparecem a Amazônia, com 9.351 registros, e a Mata Atlântica, com 5.399 focos.

Em um recorte regional, o Nordeste brasileiro se destaca pela elevada incidência de incêndios florestais. A irregularidade na distribuição espacial das precipitações, somada às altas temperaturas registradas ao longo do ano e ao uso intensivo da terra para atividades agropecuárias, constitui um conjunto de fatores que favorece sobremaneira a ocorrência desses eventos (Assis et al., 2014).

Oliveira-Júnior et al. (2022) demonstraram que, entre 1998 e 2018, os períodos de seca severa no Nordeste, em especial aqueles associados a eventos de El Niño, ampliaram significativamente a incidência de incêndios. Os autores ainda identificaram um gradiente espacial dos focos de incêndio, com maior concentração do litoral rumo ao interior, diretamente relacionado à conversão da vegetação nativa em áreas agrícolas ou degradadas.

Além disso, esses autores ressaltam que a expansão dos consórcios agrícolas, especialmente o MATOPIBA (Maranhão, Tocantins, Piauí e Bahia), tem contribuído de forma expressiva para o aumento das ocorrências de fogo, sobretudo no Cerrado e em suas áreas de transição (Oliveira-Júnior et al., 2022).

Esse padrão é corroborado por Sokolik et al. (2019), que apontam o Cerrado como o epicentro do atual *boom* agrícola brasileiro. Em 2015, apenas 13% da produção de soja do país foi colhida na Amazônia, enquanto 48% tiveram origem no Cerrado. Dentro desse bioma, a região do MATOPIBA desponta como a fronteira mais dinâmica da expansão agrícola, registrando um aumento de 253% na área destinada ao cultivo de soja entre 2000 e 2014. Esse avanço agrícola, embora estratégico para a produção nacional, tem ampliado substancialmente a pressão sobre os ecossistemas locais, elevando a vulnerabilidade do Cerrado aos incêndios.


Na mesma direção, Rocha e Nascimento (2021) ressaltam que, no Cerrado brasileiro, a interação entre os incêndios, o desmatamento e as práticas agropecuárias desempenham papel crucial, indicando uma forte correlação entre a expansão das fronteiras agrícolas e a ocorrência de queimadas. Isso se deve, sobretudo, ao uso recorrente do fogo como ferramenta nas práticas agropastoris. Vieira (2021) chama atenção para o estado do Piauí, onde a combinação de altas temperaturas, baixa umidade relativa do ar e alterações intensas na cobertura do solo configuram um cenário de alto risco para incêndios florestais.

Especificamente no Piauí, Silva e Ivata (2020) apontam o município de Uruçuí como um dos mais críticos do estado, registrando elevados números de focos de incêndio e ocasionando sérios impactos ambientais, que comprometem tanto os ecossistemas locais quanto os serviços ecossistêmicos associados.

De acordo com dados do MapBiomas (2025), entre os anos de 1985 e 2024, aproximadamente 206 milhões de hectares foram atingidos por queimadas ao menos uma vez em território brasileiro. Desse total, o bioma Cerrado foi responsável por 43,4%, o que corresponde a cerca de 89,4 milhões de hectares queimados. No contexto do semiárido brasileiro, os focos de incêndio configuram um desafio recorrente, especialmente em municípios inseridos no Cerrado, caracterizados por extensas áreas territoriais e condições de acesso limitadas, como é o caso do município de Uruçuí, localizado na microrregião do Alto Parnaíba Piauiense, no estado do Piauí.

De acordo com o Instituto Nacional de Pesquisas Espaciais (INPE, 2025), o município tem se destacado nos últimos seis anos como o principal foco de queimadas no estado, ocupando de forma recorrente a primeira posição em número de registros de focos de calor, conforme apresentado na Gráfico 1.

Gráfico 1 – Número de Focos de Calor registrados em Uruçuí – PI segundo o INPE.



Fonte: Adaptado do INPE (2025).

Entre os anos analisados, 2023 se sobressaiu com o maior número de ocorrências, totalizando 781 focos de calor. Em seguida, destaca-se o ano de 2021, com 650 registros, enquanto 2020 apresentou o menor número do período, contabilizando 484 focos. Ainda assim, mesmo no ano com menor incidência, o município manteve a liderança estadual.

Pereira e Gama (2010) destacam que os incêndios no município de Uruçuí são, em sua maioria, de origem antrópica, associados à implantação e manejo de áreas agropecuárias, sobretudo durante a estação seca. Rocha, Vieira e Silva (2022) corroboram essa análise ao enfatizar que o município se sobressai nesse contexto por ser um dos principais produtores de soja e de outros cultivos ligados à agricultura moderna. Dessa forma, o papel desempenhado pelas práticas agrícolas nessa municipalidade reflete seu processo de urbanização e desenvolvimento.

Os mesmos autores analisaram os dados do MapBiomas referentes a cobertura das terras e constataram que a área destinada ao cultivo de soja aumentou de 7.680,60 hectares em 2000 para 175.450,10 hectares em 2020. Esse crescimento representa um acréscimo de aproximadamente 2184,3% no período. Em contrapartida, as áreas classificadas como Floresta Natural diminuíram de 761.724,40 hectares para 588.093,80 hectares, correspondendo a uma redução de cerca de 22,8%. Esses resultados evidenciam a intensa expansão agrícola no município e seus impactos sobre a cobertura vegetal nativa (Rocha, Vieira e Silva, 2022).

Tão logo, o município de Uruçuí apresenta uma intensa mudança na cobertura das terras, com a remoção da vegetação nativa para cultivo de monoculturas. Portanto, é importante se estudar como as variáveis climáticas e topográficas se fazem frente a expressiva incidência de focos de incêndio florestal nessa região. Assim, o uso de geotecnologias tem se mostrado elementar para compreender essas dinâmicas ambientais, permitindo integrar essas variáveis e subsidiar estratégias de monitoramento e prevenção.

3.3 GOOGLE EARTH ENGINE (GEE)

O *Google Earth Engine* (GEE) é uma plataforma baseada em nuvem para análise geoespacial em escala planetária, que revolucionou o acesso, processamento e visualização de grandes volumes de dados de sensoriamento remoto. Lançado pelo Google em 2010, GEE é atualmente a plataforma de computação em nuvem mais popular na ciência do sistema terrestre (Zhao et al., 2021).

Nos últimos anos, o GEE tem ganhado destaque como uma das principais ferramentas para o processamento de grandes volumes de dados de sensoriamento remoto. Trata-se de uma plataforma em nuvem que utiliza a infraestrutura do Google para realizar análises geoespaciais em escala global, de forma paralelizada (Gorelick et al., 2017). Gratuito e acessível, o GEE disponibiliza um acervo de dados que alcança a ordem de *petabytes*, abrangendo mais de quatro décadas de informações provenientes de diferentes sensores, como Landsat (*Land Satellite Program*), MODIS (*Moderate Resolution Imaging Spectroradiometer*), NOAA AVHRR (*National Oceanic and Atmospheric Administration - Advanced Very High Resolution Radiometer*), Sentinel-1 (*Sentinel-1 Synthetic Aperture Radar*), Sentinel-2 (*Sentinel-2 Multispectral Instrument*), Sentinel-3 (*Sentinel-3 Ocean and Land Colour Instrument*), Sentinel-5P (*Sentinel-5 Precursor, TROPOspheric Monitoring Instrument*) e ALOS (*Advanced Land Observing Satellite*) (Gorelick et al., 2017).

O GEE reúne um vasto repositório de dados geoespaciais integrado a recursos de computação distribuída, acessíveis por meio de bibliotecas de cliente. A plataforma disponibiliza uma ampla gama de informações provenientes de satélites e de diferentes bases ambientais, além de possibilitar a incorporação de dados próprios pelos usuários. Um de seus principais diferenciais é a simplificação do processo

analítico, já que o sistema realiza de forma automática etapas como reprojeção, escalonamento e composição dos dados, de acordo com os parâmetros definidos pelo pesquisador (Google, 2025).

Além disso, a plataforma integra conjuntos de dados climáticos e geofísicos, bem como produtos derivados já prontos para uso, incluindo o Índice de Vegetação Aprimorado (EVI) e o Índice de Vegetação por Diferença Normalizada (NDVI) (Kumar & Mutanga, 2018). Outro diferencial do GEE é a oferta de imagens já pré-processadas, livres de nuvens e em mosaico, disponíveis em seu catálogo de dados, o que facilita significativamente a aplicação em estudos ambientais (Tamiminia et al., 2020).

Por possuir uma expressiva disponibilidade de dados históricos, o GEE é amplamente utilizado para estudos relacionados às mudanças ambientais, incluindo agricultura (Guerra, Schultz e Sanches 2017; Paludo, 2019), água (Mateus et al., 2021), cobertura das terras (Rocha, Vieira e Silva, 2022), mudanças climáticas (Martins, 2024), topografia (Villavicencio, Andrade e Monteiro, 2018) e urbanização (Luz et al., 2019).

No que cerne a detecção e mapeamento de queimadas, o GEE vem se destacando nos estudos de diversos autores: Arruda (2021) utilizou o GEE para desenvolver uma metodologia semi-automática que mapeia áreas queimadas no bioma Cerrado utilizando imagens do satélite Landsat e algoritmo *Deep Learning*; Martins (2024) analisou mensalmente no GEE a correlação entre variáveis climáticas – temperatura e precipitação – com áreas queimadas no estado de Rondônia; já Souza (2025) investigou os efeitos da frequência de queimadas na resposta espectral da vegetação (NDVI) na Mata Atlântica fluminense, utilizando dados do MapBiomas Fogo e imagens Landsat em uma escala multitemporal de 38 anos (1985-2023).

De forma complementar, diversos outros estudos utilizaram o ambiente do GEE para mapear a susceptibilidade a incêndios florestais ao redor do mundo. Pela ampla possibilidade dentro da plataforma, diferentes estratégias foram desenvolvidas para simular e prever o padrão espacial da probabilidade de incêndios em diferentes regiões geográficas. Alguns desses estudos usam análises de decisão multicritério para combinar informações de sensoriamento remoto e sistema de informações geográficas (GIS) para previsão de susceptibilidade a incêndios florestais,

conseguindo ultrapassar muitas vezes 90% de acurácia, quando a fusão de diferentes resoluções espaciais (Piralilou et al., 2022).

Silva Júnior (2023) analisou o perigo de incêndios florestais com base na correlação das variáveis de vulnerabilidade, com os focos de calor e o Índice de Queima Normalizada (NBR) dos anos de 2000 a 2019 do Parque Nacional da chapada dos Guimarães. Já Duarte (2022) desenvolveu uma metodologia para previsão de susceptibilidade de incêndios e queimadas utilizando um modelo baseado em inteligência artificial e Sistema de Inferência Fuzzy Híbrido, na bacia hidrográfica do rio Sorocabuçu, no município de Ibiúna/São Paulo, alcançando uma acurácia de 93,3%.

Nessa perspectiva, o GEE além de uma plataforma de alto desempenho, é um ambiente que viabiliza procedimentos reprodutíveis e operacionais para apoiar a gestão no risco de incêndios. Para áreas menores, como o caso de Uruçuí, a utilização de álgebra de mapas, seleção de critérios baseado em disponibilidade, resolução e representatividade espacial, além de produto aplicado (script disponibilizado), avança no uso da plataforma como ferramenta para uma solução metodológica replicável e aplicável à gestão em regiões de menor escala, como a nível municipal.

3.4 FATORES DE RISCO

3.4.1 Precipitação

A precipitação é vista como um fator dinâmico na probabilidade de incêndios florestais, pois está diretamente ligada ao nível de umidade da vegetação e do solo, o que afeta o potencial de ignição do fogo na área estudada. Quando a precipitação é baixa, a umidade da cobertura vegetal também diminui, elevando a probabilidade de incêndios. Além disso, a escassez de chuvas contribui para o aumento do déficit hídrico, o que, por sua vez, resulta em um maior número de focos de calor (Fragal, 2018; Akay e Şahin, 2019; Oliveira, 2019; Souza, 2022).

A umidade do ar está diretamente relacionada aos níveis de precipitação, Dias (2023) explica que a somatória dessas condições diminuí a probabilidade de ocorrência de incêndios, e caso ocorra, não se propagará, no entanto, a ausência das

chuvas com baixa umidade criam condições ideais para o início e propagação do fogo, já que umidade atmosférica abaixo de 30% é difícil de ser combatida.

Esse componente vem se destacando perante outras variáveis em diversos estudos de susceptibilidade. Souza (2022) em um mapeamento de áreas de risco a incêndios em áreas do Parque Estadual do Pau Furado em Minas Geras, utilizou uma Análise Multicritério, no qual a precipitação recebeu o maior peso pelo fato de afetar a umidade da vegetação e influenciar na inflamabilidade dos combustíveis.

Nuthammachot e Stratoulis (2021), ao mapear áreas de risco no sul da Tailândia, observaram que, embora essa região receba altos níveis de precipitação devido às monções, as variações na secura em ambientes tropicais são dinâmicas tanto temporal quanto espacialmente. Isso foi comprovado pela sobreposição dos focos de incêndios nas áreas que registraram a menor precipitação anual.

Esses resultados mostram que a dinâmica das precipitações influencia a ocorrência de incêndios tanto em zonas áridas, onde períodos prolongados de seca aumentam a vulnerabilidade, quanto em zonas tropicais, onde incêndios podem ocorrer mesmo com intervalos curtos entre as chuvas.

Em seus estudos sobre o risco de incêndios no Cerrado, Prudente (2016) classificou a precipitação mensal da seguinte forma: menos de 25 mm (risco alto), entre 25 e 75 mm (risco moderado) e acima de 75 mm (risco baixo). Por outro lado, Dias (2023), ao analisar o estado de Minas Gerais, que abrange os biomas Cerrado e Mata Atlântica, considerou a vulnerabilidade muito alta para precipitações mensais entre 0 e 100 mm, abrangendo todas as classes classificadas para o cerrado. A autora classificou como risco alto 100 à 250 mm/mensais e baixo risco as precipitações superiores a 500 mm mensais.

Medeiros, Tavares e Gomes Filho (2015) analisaram os índices pluviométricos mensais da Bacia Hidrográfica do Rio Uruçuí Preto, no Piauí — onde se localiza o município de Uruçuí —, no período de 1960 a 1990. Os autores identificaram que o quadrimestre mais chuvoso corresponde aos meses de dezembro a março, com totais mensais médios variando entre 149 mm e 175,9 mm. Já o período mais seco compreende os meses de maio a setembro, com precipitações mensais entre 1,2 mm e 22,4 mm. A média anual de precipitação registrada foi de 916 mm, com base em 31 anos de observações.

Dessa forma, considerando as classificações propostas por Dias (2023) e Prudente (2016), observa-se que, nos meses mais secos, o município de Uruçuí se enquadra simultaneamente em vulnerabilidade muito alta (Dias) e risco alto (Prudente). Já no quadrimestre mais chuvoso, a classificação diverge: enquanto Prudente o considera de risco baixo, Dias o enquadra ainda como risco alto, dado que as médias mensais permanecem abaixo do limite de 250 mm estabelecido por essa autora.

Esses dados permitem concluir que a definição de classes de precipitação para avaliar o risco de incêndios varia significativamente em função do local estudado, sendo indispensáveis observar fatores como a vegetação e o clima da região. No Cerrado, por exemplo, a adoção de valores mais baixos é adequada devido aos períodos de baixa precipitação e à presença de vegetação semidecidual, que contribuem para uma maior vulnerabilidade ao fogo. Em contraste, na Mata Atlântica, onde as características climáticas e vegetacionais são distintas, é necessário adotar outras ponderações para avaliar o risco de incêndios, refletindo a maior umidade e densidade vegetal típica desse bioma.

3.4.2 Temperatura

Segundo Soares e Batista (2007), a temperatura do ar exerce influência direta e indireta na propagação de incêndios, pois afeta a quantidade de calor necessária para que o material combustível alcance a temperatura de ignição. Dentre essas influências, a temperatura de uma região também está muito associada as características topográficas, seja pela inclinação e orientação das encostas, que afetam a incidência solar em uma superfície, ou pela altitude, que altera a composição da vegetação e pode intensificar o aquecimento causado pelo sol.

No contexto dos incêndios florestais, é essencial considerar a temperatura observando diversos fatores de um local, como condições climáticas, topografias e vegetação. Em Minas Gerais, por exemplo, Torres et al. (2018) aponta que a temperatura é mascarada pela sazonalidade: durante o verão, a estação mais quente, também é a mais úmida, o que reduz a incidência de incêndios. Por outro lado, no estado de Goiás, Goiás (2010) ressalta que o inverno é um período crítico para incêndios devido à escassez de chuvas. Durante o dia, as altas temperaturas secam

os materiais combustíveis, enquanto à noite, as temperaturas caem, aumentando a umidade desses materiais.

Nas regiões semiáridas, caracterizadas por clima quente, baixa umidade e poucas precipitações ao longo de grande parte do ano, logicamente apresentam maior propensão a incêndios. Ramalho (2013) e Bezerra et al. (2018) observaram que, no Polígono das Secas, as temperaturas médias variam de 28 °C a máximas de 40 °C, com os maiores picos concentrados no segundo semestre do ano. Por conseguinte, o RAF de 2024 (MapBiomass, 2025) mostrou que as áreas queimadas se concentraram principalmente no segundo semestre, com setembro (33%), outubro (21%) e agosto (18%) respondendo por mais de 72% da área queimada anual no país.

No escopo de estudos de susceptibilidade à incêndios, no Brasil, as dimensões continentais do país apresentam um desafio significativo: a rede de estações meteorológicas ainda é insuficiente para atender às necessidades nacionais, o que dificulta a obtenção de dados precisos em várias regiões. Além da baixa densidade dessas estações, a defasagem de tempo entre a coleta e o recebimento dos dados meteorológicos prejudica o monitoramento adequado, limitando a eficácia das ações de prevenção e controle de incêndios (Pereira et al., 2002; Melo e Fontana, 2007; Pereira et al., 2013; Pelinson et al., 2021).

Dessa maneira, a utilização de geotecnologias compensa a falta de estações meteorológicas terrestres no Brasil, fornecendo cobertura espacial ampla e dados essenciais para pesquisas ambientais e monitoramento climático (Almeida et al., 2024).

Liu et al. (2022) investigaram a relação entre os produtos mensais de temperatura da superfície terrestre (LST) obtidos pelos satélites Atmospheric Infrared Sounder (AIRS) e do MODIS, e a temperatura do ar próxima à superfície (T_a) obtida por estações durante o período de 2003 a 2016 no Brasil. Os autores observaram a LST é muito sensível a mudanças na atmosfera e no ambiente de superfície e, portanto, útil no monitoramento de mudanças ambientais, demonstrando assim uma alternativa para a utilização dessa variável na falta de estações meteorológicas, como é o caso do Brasil.

3.4.3 Cobertura Vegetal

As características dos materiais combustíveis variam de acordo com a cobertura do solo, já que o tamanho, a forma, carga de combustível e disposição do solo podem ser diferentes de lugar para outro (Pezzopani, Neto e Vilela, 2001; Dias, 2023).

A cobertura das terras indica, por um lado, a disponibilidade de materiais combustíveis e, por outro, a presença de vegetações mais resistentes a incêndios, como as formações florestais (Oliveira et al., 2020). No entanto, a intensificação das atividades humanas sobre o ambiente tem levado à substituição das paisagens naturais por outros usos e ocupações, além da fragmentação de áreas anteriormente cobertas por florestas. Nesse cenário, os incêndios florestais têm se destacado como um dos principais agentes de degradação desses fragmentos, tanto pela destruição direta quanto pelas mudanças na dinâmica dos ecossistemas impactados (Santos et al., 2010).

Essas mudanças na paisagem são especialmente preocupantes no Cerrado. De acordo com Estrabis et al. (2019), a expansão das áreas de pastagem, agricultura, queimadas e desmatamento tem sido responsável pela redução significativa da cobertura de vegetação nativa no Cerrado, resultando em impactos negativos no ecossistema e na biodiversidade da região. Nas últimas quatro décadas, esse bioma tem se tornado o foco de uma intensa atividade agrícola e expansão de pastagens.

Essa afirmação pode ser comprovada com os dados da Coleção 9 do MapBiomas (2024), revelando que entre 1985 e 2023 o Brasil perdeu 16% de suas áreas naturais, com as formações florestais e savânicas sendo as coberturas nativas mais afetadas, com reduções de 15% e 26%, respectivamente. Nesse período, o Cerrado sozinho perdeu 27% de sua vegetação nativa. Em contraste, as áreas de pastagem e agricultura foram as que mais se expandiram, com aumentos de 79% e 228%, respectivamente.

Em termos de queimadas, os dados do MapBiomas (2025) em 2024, pela primeira vez, a Formação Florestal foi a classe de cobertura mais afetada pelo fogo no país, com um valor recorde de cerca de 7,7 milhões de hectares queimados — 287% acima da média histórica, já o Cerrado, com 43,4% da área queimada pelo menos uma vez no Brasil, afetando 45,1% do bioma.

Dessa forma, é evidente a relação entre a perda da cobertura vegetal nativa e as mudanças no uso da terra com o aumento dos incêndios florestais nas mesmas regiões geográficas. Conforme a vegetação nativa vai sendo perdida, o risco de queimadas cresce, o que só agrava os impactos no meio ambiente e a destruição dos ecossistemas.

No estudo sobre a susceptibilidade a incêndios florestais no Parque Nacional da Serra da Gandarela, uma região de transição entre o Cerrado e a Mata Atlântica, Lacerda et al. (2022) identificaram a cobertura do solo como a variável mais influente no risco de incêndios. Da mesma forma, Dias (2023) apontou esse fator como um dos mais determinante para o risco de incêndios em Minas Gerais, classificando áreas de pastagem e agricultura como de risco muito alto, uma vez que são as principais responsáveis pela perda florestal no Brasil.

3.4.4 Declividade

A declividade é a inclinação da superfície de um terreno em relação ao horizonte. Segundo Soares e Batista (2007) o fogo tende a se alastrar mais rápido em subidas do que em descidas, ao tempo em que o grau de inclinação aumenta, a velocidade de propagação também aumenta. Schneider e Breedlove (s.d.) explicam que isso ocorre devido o material combustível acima está mais próximo das chamas que se movem para cima.

Schneider e Breedlove (s.d.) complementam afirmando que o calor convectivo ajuda o combustível a pegar fogo facilmente, por isso um incêndio próximo ao fundo de uma encosta se espalhará mais rapidamente durante condições diurnas do que um incêndio no topo de uma encosta, pois tem uma subida maior.

Em estudos sobre o comportamento do fogo em função do aumento da declividade, Luke e McArthur (1978) observaram que a velocidade do fogo dobra a cada 10° de inclinação. Soares (1984) chegou aos mesmos resultados em medições de incêndios de *Eucalyptus* na Austrália, e acrescentou que a velocidade quadriplica com acíves de 20°.

Soares (1985) propôs classificar a declividade em 5 classes de percentagem e adotou a cada um coeficiente de perigo a incêndios: 0-15° (baixo), 15-25° (moderado),

25-35° (alto), 35-45° (muito alto) e >45° (extremo). Em estudos mais recentes, Dias (2023) propôs uma metodologia de mapeamento de áreas de riscos a incêndios e queimadas no estado de Minas Gerais, e considerou a declividade da seguinte maneira: 0-3% (muito baixa), 3-8% (baixa), 8-20% (média), 20-45% (alta), >45% (muito alta).

Além desse componente influenciar na propagação de incêndios, Camargo *et al.* (2019) observou que regiões com grande declividade proporcionam grande dificuldade de acesso aos focos de calor, dificultando as ações de combate aos incêndios florestais.

Em um estudo na Bacia Hidrográfica do Rio Uruçuí-Preto, Figueredo, Silva e Moura (2023) apontaram com predominância de relevo plano e suavemente ondulado, com 40,08% da área classificada como plana (declividade de 0–3%) e 38,63% como suave-ondulado (3–8%). Apesar dessa predominância, eles apontaram declives acima de 20% em 14,01% da área do estudo, o que reforça a importância de considerar essa variável na avaliação do risco de incêndios florestais, especialmente em uma abordagem espacial detalhada.

3.4.5 Altimetria

Segundo Torres *et al.* (2018) a altitude é um fator relevante na ocorrência de incêndios, pois, à medida que aumenta, ocorre uma redução no porte da vegetação. Em determinadas altitudes, as formações florestais dão lugar a áreas campestres, mais suscetíveis a incêndios. Essa dicotomia ficou evidente em seu estudo no Parque Estadual Serra do Brigadeiro, em Minas Gerais, na medida que a altitude aumentava, houve um crescimento na área queimada devido à mudança no tipo de material combustível, seguido por uma redução na área afetada, resultante do aumento da umidade do ar.

Além disso, regiões de maior altitude tendem a receber mais precipitação e apresentar temperaturas mais baixas, o que aumenta a umidade dos combustíveis mortos (Nieto *et al.*, 2012). O mapa hipsométrico pode, em certa medida, indicar o teor de umidade do material combustível (Prudente, 2016).

Dias (2023) destaca que a presença humana é um fator relevante relacionado à altitude, uma vez que as pessoas tendem a se estabelecer e trabalhar em áreas de menor altitude, onde o terreno é mais plano, resultando em custos e demanda de mão de obra menores. Consequentemente, a maioria dos incêndios e queimadas ocorre em regiões baixas e com pouca declividade.

Esse componente é essencial no estudo desses fenômenos. Por exemplo, Tian et al. (2013) evidenciou que, na China, a maioria dos incêndios florestais acontece em áreas de baixa altitude, com 54% dos incêndios ocorrendo em altitudes abaixo de 500 metros, 20% entre 501 e 1000 metros, e 15% em elevações de 1001 a 2000 metros. Apenas 10% dos incêndios ocorreram em altitudes superiores a 2000 metros.

Estevam (2020), ao analisar áreas suscetíveis a incêndios florestais no Parque Estadual do Itacolomi, observou que a altitude foi a variável que mais influenciou os focos de queimadas, superando outras, como declividade, radiação solar e rede viária. A importância dessa variável também foi destacada nos estudos de Tomzhinski (2012) sobre o Parque Nacional do Itatiaia, que demonstrou uma grande concentração de incêndios em altitudes entre 1000 e 2000 metros, abrangendo 71% dos casos analisados e 39% dos incêndios maiores que 10 hectares.

3.4.6 Orientação das Encostas (Aspecto)

A orientação de uma encosta determina a quantidade de incidência solar que uma superfície recebe, e por consequência, o aumento no risco de incêndios. De acordo com Pezzopane et al. (2000), a inclinação do terreno desempenha um papel importante na determinação do balanço de radiação, o que, por sua vez, influencia a quantidade de energia disponível para processos como evapotranspiração, aquecimento e resfriamento do solo e do ar, além da fotossíntese. Em áreas com relevo irregular, a irradiância solar varia conforme o grau de inclinação e a orientação do terreno em relação ao trajeto solar, especialmente em regiões de latitudes mais altas.

De acordo com Goiás (2010), encostas voltadas para o sul tendem a registrar temperaturas mais baixas devido à menor exposição direta ao sol, em comparação com as encostas voltadas para o norte. Schneider e Breedlove (s.d.) apoia essa afirmação, acrescentando que as encostas voltadas ao norte geralmente possuem

materiais combustíveis mais leves, temperaturas mais elevadas e menor umidade dos combustíveis, o que as torna mais propensas ao início e propagação de incêndios.

Com base nessa lógica, Dias (2023) classificou a orientação das encostas da seguinte forma: as encostas do hemisfério sul que estão expostas ao Norte (N) recebem mais incidência solar, elevando o grau de risco muito alto a incêndios; para Noroeste (NO) e Oeste (O), por durante a manhã serem aquecidas pela incidência solar difusa (mais lenta), e a tarde receberem de forma direta, tornando-as secas e quente, possuindo risco alto; Nordeste (NE) com risco médio; Leste (E) no entanto, risco baixo, por receberem incidência direta pela manhã e iniciarem o processo de resfriamento a tarde; e seguindo o raciocínio, as orientações Sul (S), Sudeste (SE) e Sudoeste (SO) e áreas de relevo plano com risco muito baixo. A autora explica que a orientação das vertentes influencia na temperatura e criam condições edafoclimáticas locais diferentes entre uma face e outra.

Ramalho *et al.* (2021) em um estudo sobre a alocação de reservatórios de água para combate a incêndios na Floresta Nacional do Rio Preto (FLONA do Rio Preto, Espírito Santo) propôs uma classificação de risco conforme o grau de inclinação em 360°. As faces norte (próximas a 0° e 360°) foram consideradas com maior risco, e as de face sul (valores próximos a 180°) foram consideradas de menos risco.

Medeiros, Holanda e França (2018) apontam que as regiões desérticas são aquelas que mais recebem incidência solar, e destacam que o semiárido do Nordeste brasileiro apresenta níveis de insolação comparáveis aos de áreas desérticas. No estado do Piauí, os autores observaram um aumento significativo nas horas de incidência solar, especialmente no segundo semestre do ano, alcançando uma média mensal de 319,0 horas.

Logo, as áreas com vertentes voltadas para o norte no estado do Piauí tendem a apresentar condições mais propícias à ignição e propagação de incêndios florestais, devido à maior incidência solar ao longo do ano, especialmente nos períodos mais secos. Essa orientação favorece o ressecamento dos combustíveis vegetais, aumenta as temperaturas locais e reduz a umidade relativa do ar e do solo, criando um ambiente mais vulnerável ao fogo.

3.5 ANÁLISE MULTICRITÉRIO

As tomadas de decisão são relativamente simples quando se considera um único critério: escolhe-se a alternativa de maior preferência. Já quando se trata de múltiplos critério, a escolha se torna mais complexa e exige procedimentos estruturados para lidar com comparações simultâneas e possíveis conflitos entre os objetivos. Diante disso, houve-se a necessidade de se desenvolver métodos de decisão multicritério como um campo próprio de investigação e prática (Tzeng & Huang, 2011).

A análise multicritério tem como principal objetivo apoiar escolhas alinhadas aos objetivos do decisor, em circunstâncias de dúvidas, incertezas, conflitos de informações e concorrência entre vários critérios (Parreiras, 2006). Schroeder (2020) e Costa (2002) destacam que a subjetividade é inerente nos processos de decisão, pois a alternativa pode parecer a melhor para um decisor e não para outro, no entanto, uma das características centrais das metodologias de tomada de decisão é justamente a capacidade de reconhecer a subjetividade como algo explícito aos problemas de decisão e, assim, utilizar julgamento de valor de forma cientificamente justificável.

Nas análises ambientais, onde ocorre um processo complexo que envolve inúmeras variáveis e critérios, a Análise Multicritério tem sido amplamente empregada para apoiar a tomada de decisão, permitindo atribuir valores relativos às variáveis, hierarquizá-las por pesos conforme o contexto e, a partir dessa síntese, derivar conclusões (Carvalho, et al., 2011; Weiss e Pippi, 2019; Peixoto et al., 2019; Ladislau et al., 2021; Domiciano, 2024).

A exemplo, Feizizadeh e Blaschke (2012) e Hillet et al. (2005) mostram a decisão multicritério como um processo de combinação e transformação de dados geográficos e juízos de valor, articulado por diferentes algoritmos que flexibilizam a geração de informação indispensável à definição e priorização espacial. Nessa perspectiva, a abordagem se consolida, por exemplo, como instrumento estratégico de planejamento territorial, oferecendo critérios transparentes para sustentar escolhas em graus distintos de restrição e prioridade.

Muitas abordagens de Análise Multicritério foram desenvolvidas para ajudar a tomada de decisões em diversos ambientes, dentre os métodos mais conhecidos

estão: Processo de Análise Hierárquica (AHP, *Analytic Hierarchy Process*); Método de Análise em Rede (ANP, *Analytic Network Process*); ELECTRE (*Elimination et Choix Traduisant la Réalité*); TODIM (Tomada de Decisão Interativa Multicritério); TOPSIS (*Technique for Order Preference by Similarity to Ideal Solution*) e MAUT (*Multiple Attribute Utility Theory*)(Schroeder, 2020).

Entre os métodos de maior destaque na tomada de decisão multicritério está o Processo de Análise Hierárquica (AHP), amplamente reconhecido por sua versatilidade e por ser um dos procedimentos mais utilizados em diferentes áreas do conhecimento, como saúde, engenharia, gestão ambiental, planejamento urbano, transporte, construção civil e gestão de cadeias de suprimentos. Sua ampla adoção decorre da capacidade de estruturar problemas complexos em uma hierarquia clara de objetivos, critérios e alternativas, permitindo comparações par a par e favorecendo a priorização consistente entre as opções avaliadas (Hamurcu & Eren, 2020).

Quando se trata da elaboração de mapas de risco de incêndios florestais — que demandam análises espaciais integrando múltiplas variáveis em ambiente SIG — o AHP destaca-se como um dos métodos mais utilizados, graças à sua capacidade de organizar variáveis heterogêneas, permitir comparações par a par e atribuir pesos consistentes para a síntese final do risco (Jaiswal et al., 2002).

3.6 PROCESSO DE ANÁLISE HIERÁRQUICA (AHP)

A associação de técnicas de geoprocessamento com métodos de análise de dados e suas particularidades vem ao longo dos anos se tornando frequente e possibilitando uma maior percepção das áreas estudadas, sobretudo na avaliação de susceptibilidades ambientais. Uma das metodologias de Análise Multicritério que se destaca na análise de dados é o Método AHP (sigla em inglês para Processo de Análise Hierárquica), que segundo Mourão (2020), foi criado na década de 70 por Thomas Saaty, e consiste na manipulação das avaliações de alternativas perante um problema complexo, atribuindo hierarquização de cada alternativa diante de todos os componentes de estudo.

Segundo Andrade (2021), o AHP é um método sistemático utilizado para apoiar a tomada de decisões e o planejamento em contextos complexos, nos quais múltiplos critérios ou variáveis precisam ser avaliados para definir prioridades e escolher entre

diferentes alternativas ou projetos. Para Vieira (2006), o método se fundamenta em três princípios essenciais: primeiro a construção de hierarquias, que consiste na decomposição do critério principal em níveis mais específicos; a definição de prioridades, estabelecidas por meio de comparações entre pares de elementos com base em um critério determinado; e a consistência lógica, que é verificada por meio de índices que avaliam se os julgamentos realizados na definição das prioridades são coerentes.

Na análise, utiliza-se uma matriz de comparações, por meio da qual o método AHP aplica cálculos de autovalores e autovetores para determinar os pesos relativos entre os critérios ou fatores considerados. Esses pesos são posteriormente normalizados, resultando em uma escala que expressa a prioridade relativa de cada elemento (Saaty, 1990). Os conceitos de autovalores e autovetores, originários da matemática, permitem quantificar a importância de cada fator ou alternativa dentro do processo decisório.

O processo de avaliação de importâncias e pesos, tanto das classes quanto das variáveis em análise, segue um modelo de escala de prioridades proposto por Saaty (1980), em uma variação entre classes e variáveis que menos contribuem para o processo estudado as variáveis que possuem contribuição significativa e/ou absoluta (Quadro 1).

Quadro 1 – Escala Fundamental de Saaty.

Grau de importância	Definição	Descrição
1	Importância igual	As duas atividades contribuem igualmente para o objetivo.
3	Importância Moderada	A experiência e o julgamento favorece moderadamente uma atividade em relação à outra.
5	Importância Forte	A experiência e o julgamento favorece fortemente uma atividade em relação à outra.
7	Importância Muito Forte	Uma atividade é muito fortemente favorecida em relação à outra e sua

		dominação de importância é demonstrada na prática.
9	Importância Extrema	A evidência favorece uma atividade em relação à outra com o mais alto grau de certeza.
2,4,6 e 8	Valores intermediários	Quando se procura uma condição de compromisso entre duas definições.
Números racionais	Razões resultantes da escala.	Se a consistência tiver de ser forçada para obter valores numéricos n , somente para completar a matriz.

Fonte: Adaptado de Saaty (1980).

Em seguida, realiza-se a etapa de comparação entre os elementos, atribuindo-se valores de importância com base na tabela anterior. A Matriz de Comparação de Julgamentos é construída ao preencher cada célula com um valor que representa a relevância relativa entre os elementos. Essa comparação é feita por meio de uma matriz quadrada, cuja dimensão corresponde à quantidade de elementos vinculados ao nível hierárquico imediatamente superior (Quadro 2). Os elementos subordinados são organizados na mesma sequência tanto nas linhas quanto nas colunas da matriz (Ribeiro e Alves, 2016; Dias, 2023).

Quadro 2 – Estrutura de uma matriz quadrada ($n \times n$) de critérios.

C₁	a₁	a₂	...	n_a
a₁	1	x_{12}	...	x_{1n}
a₂	$1/x_{12}$	1	...	x_{2n}
...	...	...	...	...
a_n	$1/x_{n1}$	$1/x_{n2}$	...	1

Fonte: Dias (2023).

A matriz é quadrada e de ordem n , onde n é o número de elementos comparados. Os valores atribuídos são recíprocos, ou seja, se o elemento a_1 é considerado três vezes mais importante que o elemento a_2 (valor 3 na célula a_{12}), então o elemento a_2 terá um valor de $1/3$ na célula a_{21} .

Com a matriz preenchida, o próximo passo é calcular os pesos relativos dos critérios. Isso é feito a partir do cálculo do autovalor principal da matriz de comparação. Esse autovalor corresponde aos pesos normalizados que expressam a prioridade relativa de cada critério. Simultaneamente, calcula-se o autovalor máximo ($\lambda_{\max}$), que é utilizado para verificar a consistência dos julgamentos feitos.

A consistência dos julgamentos é essencial para garantir a confiabilidade do modelo. Para isso, calcula-se o **Índice de Consistência (IC)**, dado pela equação 1:

$$IC = \frac{\lambda_{\max} - n}{n - 1} \quad (\text{Equação 1})$$

Em que $\lambda_{\max}$ é o autovalor máximo da matriz, e n é o número de critérios comparados. Quanto mais próximo $\lambda_{\max}$ estiver de n , mais consistente é a matriz. Para encontrar o valor de $\lambda_{\max}$ é utilizada a seguinte equação (Equação 2):

$$\lambda_{\max} = \frac{1}{n} \sum_{i=1}^n v_i \frac{Aw_i}{w_i} \quad (\text{Equação 2})$$

Onde: A é a matriz de comparação par a par; w é o vetor de pesos (autovetor normalizado); Aw_i representa o produto da linha i da matriz pelo vetor de pesos; w_i é o peso correspondente ao critério i e n é o número de critérios.

Para interpretar o valor do IC, utiliza-se o **Índice Aleatório (RI)**, conforme Tabela 1 que é uma média dos ICs obtidos de matrizes aleatórias de mesma ordem n .

Tabela 1 – Valores de Índice Aleatório.

1	2	3	4	5	6	7	8	9	10
0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49

Fonte: Saaty (1991).

Saaty (1991) forneceu os valores de RI para diferentes tamanhos de matriz. A relação entre IC e RI é expressa pela **Razão de Consistência (RC)**:

$$RC = \frac{IC}{RI} \quad (\text{Equação 3})$$

Caso o valor de CR seja menor ou igual a 0,10 (10%), considera-se que os julgamentos possuem consistência aceitável. Se o valor for superior, recomenda-se revisar a matriz de comparação, pois há indícios de incoerência nas preferências expressas.

Segundo Dias (2023), os métodos convencionais para avaliar o risco de queimadas e incêndios apresentam limitações, sendo geralmente caros, lentos e pouco precisos. Em contraste, os sistemas de informação geográfica (SIG) aliados à detecção remota possibilitam a identificação de diversas variáveis, oferecendo análises mais rápidas, econômicas e com elevado grau de precisão. A integração entre o SIG e as técnicas de análise de decisão multicritério mostra-se, assim, uma abordagem eficiente para o mapeamento do risco de queimadas, especialmente diante da complexidade e da variedade de fatores envolvidos nesse tipo de avaliação.

Esse método foi utilizado por diversos outros autores para detecção de áreas de risco a incêndios. Arias-Muñoz et al. (2024) utilizou 11 variáveis, sendo topográficas (altitude, declive, orientação do terreno), climáticas (precipitação, temperatura, evapotranspiração potencial, déficit hídrico e velocidade do vento) e antrópicas (cobertura do solo, proximidade de estradas e proximidade de áreas agrícolas), para determinar áreas susceptíveis a incêndios de cobertura vegetal no cantão de Cotacachi no Equador. A eficácia do modelo foi avaliada por meio da métrica AUC (Área sob a Curva), que indica o grau de acerto do modelo – quanto mais próximo de 1, melhor o desempenho. O modelo baseado em AHP obteve valores de AUC de 0,824 e 0,748 em diferentes bases de validação, indicando boa correspondência com dados reais e demonstrando sua capacidade de identificar áreas com maior risco de incêndios.

White, White e Ribeiro (2021) utilizaram as variáveis de densidade demográfica, sistema viário, cobertura das terras, malha hidrográfica, inclinação e orientação das encostas para determinar as áreas de risco a incêndios florestais no município de Inhambupe, na Bahia, particularmente predominado de plantio de eucalipto. Com a aplicação do método, observaram que 95% das áreas queimadas coincidiram com as zonas de maior risco, demonstrando um resultado consistente.

Já Domiciano (2024) utilizou dados de declividade, altimetria, orientação das encostas, cobertura das terras e variáveis mais dinâmicas, como temperatura, precipitação, umidade relativa e balanço hídrico para determinar as áreas com risco na bacia hidrográfica do Médio Paraíba do Sul no Rio de Janeiro, concluindo que o município de Itatiaia, possuía grande área de risco alto.

3.7 ÁLGEBRA DE MAPAS

A Álgebra de Mapas pode ser entendida como uma linguagem ou metodologia formal voltada à análise e à síntese de informações espaciais, baseada na organização de dados cartográficos em camadas e na aplicação de operações que permitem interpretar e transformar essas informações no contexto dos sistemas de informações geográficas (Chan e Tomlin, 1991; Tomlin, 1994).

Originalmente proposta por Dana Tomlin, a álgebra de mapas utiliza funções para tratar dados espaciais contínuos, permitindo modelar problemas diversos e extrair novas informações a partir dos dados existentes. Além disso, ela é baseada na representação uniforme do espaço em grades discretas organizadas em camadas, possibilitando operações matemáticas sobre essas camadas para estudar padrões espaciais (Câmara et al., 2005).

Tomlin (1994) classificou a Álgebra de Mapas em quatro tipos principais de operações: Operações Locais (local) que calculam um novo valor para cada localização com base no valor que já existe naquela mesma posição, em uma ou mais camadas; Operações Zonais (zonal) que calculam um novo valor para cada localização considerando os valores da zona à qual ela pertence; Operações Focais (focal) que calculam um novo valor para cada localização com base nos valores das vizinhanças ao redor dela; e Operações Incrementais (incremental) que calculam um novo valor para cada localização em função de sua forma linear, areal ou superficial, como comprimento, área, frente, declividade, aspecto e direção de drenagem.

No contexto do GEE, a plataforma consegue desenvolver operações locais, quando os cálculos são realizados pixel a pixel entre bandas ou imagens, como em expressões matemáticas, índices espectrais e reclassificações (Mennis, 2022); operações focais, quando o valor de cada pixel passa a depender de sua vizinhança, por meio de janelas móveis, kernels e estatísticas de entorno (Estévez et al., 2022); operações zonais, quando os valores são resumidos em zonas definidas por polígonos, classes ou regiões de interesse (Mennis, 2022) e operações incrementais, quando a análise considera a cobertura ou a coleção de imagens como um todo, como nas composições e reduções estatísticas aplicadas a *ImageCollections* (Estévez et al., 2022).


Diversos trabalhos que tiveram por objetivo realizar o mapeamento de áreas de risco a incêndios florestais utilizaram as operações classificadas por Tonlim (1994) dentro do ambiente GEE. Jodhani et al., (2021) avaliou a severidade de incêndios florestais e temperatura da terra utilizando múltiplas camadas *raster* via operações locais e focais. Olga et al., (2024) também utilizaram operações focais para determinar o perigo de fogo em pastagens de parque montanhoso (África do Sul) utilizando técnicas de aprendizagem de máquina com variáveis ambientais.

4 METODOLOGIA

4.1 DELIMITAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO

Uruçuí está localizado na microrregião do Alto Parnaíba Piauiense (Figura 1), compreende uma área de 8.413,002 km² (IBGE, 2022), tem como limites os municípios do estado do Maranhão e Antônio Almeida ao norte, Palmeiras do Piauí e Alvorada do Gurguéia ao sul, Sebastião Leal, Landri Sales e Manoel Emídio a leste, e Ribeiro Gonçalves, estado do Maranhão e Baixa Grande do Ribeiro a oeste, conforme Figura 1. A sede municipal tem as coordenadas geográficas de 07°13'46" de latitude sul e 44°33'22" de longitude oeste de Greenwich e uma distância de 453 km da capital Teresina (Aguiar, 2004). A população total, segundo o Censo 2022 do IBGE, é de 25.203 habitantes, apresentando uma densidade demográfica de 3,00 hab/km².

Figura 1 – Mapa de Localização de Uruçuí – PI.



Fonte: Os autores (2025).

Politicamente emancipado pela Lei nº 290, de 23 de junho de 1902, o município de Uruçuí desenvolveu-se às margens de três importantes rios — Parnaíba, Uruçuí Preto e Balsas — que compõem sua paisagem fluvial. O processo de emancipação foi impulsionado, sobretudo, pelo crescimento da navegação entre as cidades piauienses de Parnaíba, Teresina e Floriano, estendendo-se também até o município maranhense de São Félix de Balsas (Uruçuí, 2021, apud Rocha, Vieira e Silva, 2022).

Segundo a classificação climática de Köppen, o município apresenta clima tropical, caracterizado por altas temperaturas e regime sazonal de chuvas. O período chuvoso se concentra entre novembro/dezembro e abril/maio, enquanto a estação seca ocorre nos meses restantes. As temperaturas médias variam de 20°C a 31°C, e a precipitação anual situa-se entre 800 e 1200 mm, configurando um ambiente quente e úmido típico da região (Neves et al., 2015).

Do ponto de vista geológico, Uruçuí repousa sobre duas formações sedimentares distintas. A Formação Piauí, datada do período Carbonífero, é composta por arenitos, siltitos, folhelhos e calcários. Já a Formação Pedra de Fogo, do período Permiano, apresenta constituição variada, incluindo arenitos, folhelhos, calcários e sílexitos, compondo um cenário geológico diversificado que marca a base estrutural do município (Brasil, 2006).

4.2 SELEÇÃO DOS DADOS AMBIENTAIS

A seleção do conjunto de variáveis utilizadas partiu do entendimento que não há um consenso universal sobre o quais indicadores devem compor mapas de suscetibilidade/risco de incêndios, uma vez que sua relevância varia conforme o contexto ambiental e a escala do estudo (Chicas; Nielsen, 2022). Para o presente estudo, a seleção das variáveis foi conduzida com base em evidência científica, disponibilidade e qualidade dos dados no GEE, e compatibilidade espacial (resolução e escala) com a dimensão do município.

Na etapa bibliográfica, utilizou-se a revisão sistemática de Chicas e Nielsen (2022) que analisou estudos de risco a incêndios e identificou um conjunto de fatores empregados em modelos de mapeamento. Os autores extraíram 144 fatores de 94 artigos, destacaram 33 fatores recorrentes (aqueles presentes em três ou mais modelos), e como base nesse universo, foi extraído os 10 fatores mais utilizados e ranqueados como essenciais: declividade, altitude, distância a estradas, distância a áreas residenciais, uso/cobertura da terra, NDVI, temperatura, precipitação, velocidade do vento e aspecto (orientação de encostas).

A partir desses 10 fatores, foi realizada uma adaptação ao contexto de Uruçuí-PI, mantendo-se as variáveis que apresentavam forte respaldo na literatura e possuíam produtos com resolução adequada e consistência espacial para uma análise municipal, sendo eles:

- Distância a áreas residenciais: excluída por baixa representatividade espacial no contexto municipal, dado que a mancha urbanizada representa apenas 0,37% do território do município (Rocha, Vieira e Silva, 2022) se concentra principalmente na

sede, resultando em um gradiente espacial restrito e pouca capacidade discriminativa para o risco ambiental ao longo do território.

- Distância a estradas: excluída pela baixa densidade de rodovias no município, apenas 37 feições observada nos dados do Global Roads Inventory Project (GRIP4) e limitações para representar adequadamente estradas vicinais com qualidade cartográfica e completude consistentes em bases vetoriais de uso imediato no GEE.

- Uso/Cobertura da terra: para evitar redundância como NDVI, optou-se por não utilizar a cobertura da terra, já que o NDVI fornece uma medida contínua do estado da vegetação (vigor verde), capaz de capturar variações relevantes para a disponibilidade de combustível, o que torna mais informativo para a lógica do índice multicritério.

- Velocidade do vento: essa variável foi descartada devido à incompatibilidade entre a resolução espacial disponível e a escala municipal, o que reduz a representatividade do fenômeno no produto final. No catálogo do GEE, os produtos que disponibilizam componentes de ventos próximos a superfície são o 'ECMWF/ERA5/DAILY', que fornece pixels de aproximadamente 11 km e o 'NOAA/GFS0P25', que disponibiliza pixels de aproximadamente 28km de resolução, resultando em poucas células cobrindo o município e baixa variabilidade interna, o que limita o poder de discriminação espacial do critério no mapa final.

Dessa forma, o conjunto final de variáveis priorizou fatores com maior consistência teórica e melhor compatibilidade espacial para Uruçuí-PI, mantendo-se declividade, altitude, aspecto, NDVI, temperatura e precipitação. Tais variáveis foram obtidas e processadas diretamente no GEE, com posterior recorte espacial para o município de Uruçuí, conforme os limites definidos pelo Instituto Brasileiro de Geografia e Estatística (IBGE).

4.3 PROCESSAMENTO DOS DADOS

A implementação do procedimento metodológico foi realizada no ambiente *Code Editor* do *Google Earth Engine*, utilizando a linguagem *JavaScript*, nativa do editor e amplamente adotada na plataforma para criação de scripts reprodutíveis. A escolha do GEE se justificou por sua capacidade de processar grandes volumes de

dados geoespaciais de forma eficiente, integrando diferentes sensores e séries temporais com ferramentas analíticas robustas.

Neste trabalho, o *JavaScript* teve papel instrumental na execução do fluxo completo: consulta e filtragem de coleções, recorte espacial para a área de estudo, composições e estatísticas temporais, reclassificações/normalizações, integração por álgebra de mapas e geração dos produtos cartográficos.

O desenvolvimento do código ocorreu de forma incremental e orientada por regras explícitas definidas a partir das variáveis selecionadas na literatura, do catálogo de dados do GEE e das características de cada produto, especificamente a cadência temporal e resolução espacial. Para cada variável, o script foi estruturado seguindo o padrão:

- 1) Identificação e seleção do dataset no catálogo do GEE e definição do recorte espacial para o município;
- 2) Definição da janela temporal conforme a periodicidade do produto, empregando os dados mais recentes disponíveis e agregações compatíveis com o fenômeno;
- 3) Pré-processamento e controle de qualidade, incluindo filtrações, seleção de cenas válidas e tratamento de dados ausentes quando necessário;
- 4) Padronização/normalização e reclassificação para escala comum [0,1], todas as camadas foram convertidas para valores adimensionais entre 0 e 1, conforme prática adotada em estudos multicritério de suscetibilidade/risco (Ghorbanzadeh et al., 2019; Nikolić et al., 2023; Ju et al., 2023), em que 0 representa a menor contribuição ao risco e 1 representa a maior contribuição ao risco;
- 5) Integração por álgebra de mapas mediante combinação ponderada;
- 6) Classificação e geração de saídas.

Por fim, o script foi documentado por comentários e organizado em blocos lógicos, como a entrada de dados, o processamento por variável, a integração e as saídas, garantindo reprodutibilidade do procedimento.

4.3.1 Temperatura

Os dados utilizados neste estudo foram obtidos a partir de imagens do sensor MODIS, utilizando-se os produtos MOD11A1.061 – Terra Land Surface Temperature and Emissivity Daily Global 1km (MODIS/061/MOD11A1) e MYD11A1.061 – Aqua Land Surface Temperature and Emissivity Daily Global 1km (MODIS/061/MYD11A1), amplamente empregados na caracterização de variáveis da superfície terrestre (Running et al., 1994). Esses produtos disponibilizam a temperatura da superfície em duas bandas principais: ‘LST_Day_1km’ (temperatura diurna) e ‘LST_Night_1km’ (temperatura noturna), ambas com resolução espacial de 1 km.

Os valores de temperatura são disponibilizados na escala Kelvin e codificados como inteiros escalados. Para sua conversão em graus Celsius, foi adaptado o código proposto por Ferreira et al. (2017), realizando-se inicialmente a seleção das bandas mencionadas e, em seguida, aplicando-se o fator de escala e a transformação para a escala Celsius.

Para reduzir lacunas pontuais na imagem — sobretudo em períodos chuvosos e nublados — adotou-se um procedimento em duas etapas, priorizando dados recentes e completando pixels sem observação válida. Inicialmente, identificou-se a data mais recente disponível para o município e definiu-se uma janela móvel de 7 dias encerrando-se nessa data; dentro dessa janela, as coleções (Terra e Aqua) foram filtradas e as bandas convertidas para °C, calculando-se a média temporal do período. Em seguida, para os locais em que a composição de 7 dias ainda apresentasse pixels mascarados, foi calculada uma média adicional de 30 dias (também encerrando-se na data mais recente), utilizada apenas para completar pontualmente as áreas sem valor na composição principal. A temperatura combinada foi então obtida pela média entre as bandas diurna e noturna e posteriormente recortada ao limite municipal.

Com a imagem de temperatura combinada definida, a variável foi convertida para uma escala adimensional [0,1], de modo a permitir sua integração multicritério com as demais camadas. Para isso, foram obtidos, dentro da área de estudo, os valores mínimos (LST_min) e máximo (LST_max) da temperatura combinada, e aplicou-se a normalização do tipo min-max:

$$LST_{norm} = \frac{LST - LST_{min}}{LST_{max} - LST_{min}} \quad (\text{Equação 4})$$

Nessa padronização, 0 (zero) representa a menor temperatura observada na área municipal na composição considerada (menor contribuição ao risco) e 1 (um) representa a maior temperatura observada no município (maior contribuição ao risco)

Por fim, a data mais recente utilizada para ancorar a janela, o intervalo de 7 dias efetivamente considerado e a média da temperatura combinada foram apresentadas no console.

4.3.2 Precipitação

Para os dados de precipitação, foi utilizada a base CHIRPS Daily: *Climate Hazards Center InfraRed Precipitation with Station Data Versão 2.0 Final* (UCSB-CHG/CHIRPS/DAILY), que fornece informações diárias de precipitação em milímetros por dia (mm/dia), com resolução espacial de aproximadamente 5 km.

No processamento, para cada data de referência do índice, foi definida uma janela temporal acumulada de 15 dias, compreendendo os 14 dias anteriores e o dia corrente. A coleção CHIRPS foi filtrada para esse intervalo e, em seguida, calculou-se a soma da precipitação no período, recortando-se o resultado ao limite municipal de Uruçuí.

Essa configuração foi adotada por permitir melhor representação da memória hídrica de curto prazo da paisagem, condição mais compatível com os processos de secagem do combustível vegetal e, conseqüentemente, com a suscetibilidade à ocorrência de incêndios. Essa adoção já foi feita em outros estudos que destacam a importância de condições meteorológicas antecedentes e de variáveis associadas à umidade do combustível para a previsão e compreensão da atividade do fogo, a exemplo de Wang et al. (2023) e Bendick e Hoylman (2020).

Para permitir a integração multicritério, o acumulado de precipitação em 15 dias foi convertido para uma escala adimensional [0,1] na qual 0 representa a menor contribuição ao risco e 1 representa a maior contribuição ao risco. Inicialmente, foram obtidos os valores mínimos (P_{min}) e máximo (P_{max}) da imagem de precipitação média dentro da área municipal. Em seguida, aplicou-se a transformação de inversão:

$$P_{inv} = P_{max} - P \quad (\text{Equação 5})$$

Em que P é a precipitação acumulada em 15 dias por pixel. Essa transformação garante que áreas com maior precipitação apresentem valores menores (menor suscetibilidade) e áreas com menor precipitação apresentem valores maiores (maior suscetibilidade).

Na sequência, P_{inv} foi normalizado para o intervalo $[0, 1]$ por divisão pelo alcance da precipitação no município, $(P_{max} - P_{min})$, resultando na camada final utilizada no índice:

$$P_{risco} = \frac{P_{inv}}{(P_{max} - P_{min})} \quad (\text{Equação 6})$$

Assim, na camada P_{risco} , 0 corresponde à condição de maior precipitação observada no município (menor risco) e 1 corresponde à condição de menor precipitação observada (maior risco) na composição considerada.

4.3.3 Cobertura Vegetal (via NDVI)

O Índice de Vegetação por Diferença Normalizada (NDVI) é uma técnica amplamente utilizada no processamento de imagens de sensoriamento remoto para identificar a presença de vegetação e caracterizar sua distribuição espacial (Gameiro et al., 2016; Barbosa, Carvalho e Camacho, 2017; Lobato, Gomes e Palhares, 2025). Com base nesse indicador, a avaliação da cobertura vegetal neste estudo foi realizada a partir dos dados do *Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A* (COPERNICUS/S2_SR_HARMONIZED), que fornece as bandas B4 (vermelho) e B8 (infravermelho próximo – NIR), ambas com resolução espacial de 10 metros.

Esse produto, por ser de nível 2A, já possui correção atmosférica aplicada, o que elimina a necessidade de correções adicionais antes do cálculo do NDVI.

O processamento foi configurado para privilegiar dados recentes e, simultaneamente, reduzir lacunas espaciais associadas à alta nebulosidade, especialmente durante o período chuvoso, quando a presença de nuvens e sombras pode mascarar parte significativa dos pixels. Assim, adotou-se uma estratégia em duas etapas: inicialmente, foram selecionadas imagens dos últimos 30 dias; em seguida, para os locais em que a composição desse período ainda apresentasse pixels mascarados por nuvens/sombra, utilizou-se uma composição adicional com

imagens dos últimos 60 dias, de modo a completar áreas pontualmente sem observação válida no período mais recente. A detecção e remoção de pixels contaminados foi realizada no nível do pixel por meio da banda SCL (*Scene Classification Layer*) do Sentinel-2, permitindo descartar nuvens e sombras sem eliminar totalmente cenas que ainda contivessem informação útil.

Em seguida, foi gerado um mosaico das cenas selecionadas e calculado o NDVI pela relação:

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (\text{Equação 9})$$

Após o cálculo do NDVI, a imagem foi convertida para uma escala adimensional [0,1] dentro da área de estudo, com base nos valores mínimo ($NDVI_{min}$) e máximo ($NDVI_{max}$) observados no município, por normalização do tipo min-max:

$$NDVI_{esc} = \frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \quad (\text{Equação 10})$$

Nessa etapa, $NDVI_{esc} = 0$ representa o menor vigor/cobertura vegetal observado em Uruçuí e $NDVI_{esc} = 1$ representa o maior vigor/cobertura vegetal. Como, para o risco de incêndio, a relação considerada é inversa (maior cobertura vegetal representa menor risco), aplicou-se a inversão da escala para manter a coerência do índice final (no qual valores maiores representam maior suscetibilidade):

$$NDVI_{risco} = 1 - NDVI_{esc} \quad (\text{Equação 11})$$

Assim, na camada

$NDVI_{risco}$, 0 corresponde às áreas com maior NDVI (maior cobertura vegetal e menor risco) e 1 corresponde às áreas com menor NDVI (menor cobertura vegetal e maior risco), sendo $NDVI_{risco}$ a variável utilizada na etapa de integração multicritério.

4.3.4 Declividade

Os dados de declividade foram derivados a partir do Modelo Digital de Elevação (MDE) SRTM (*Shuttle Radar Topography Mission*), obtido por meio do *dataset* “USGS/SRTMGL1_003”, o qual possui resolução espacial de 30 metros. A inclinação

do terreno foi calculada utilizando a função *ee.Terrain.slope()*, que estima a declividade em graus com base nas variações altimétricas do modelo de elevação.

Para integrar a declividade ao modelo de suscetibilidade, os valores foram padronizados para uma escala adimensional [0,1] por meio da função *unitScale(0, 90)*, considerando que a declividade varia de 0° (terreno plano) a 90° (inclinação vertical). Nessa padronização, 0 corresponde às áreas com declividade mínima (0°), interpretadas como menor contribuição ao risco segundo a lógica adotada, enquanto 1 corresponde às áreas com declividade máxima (90°), representando maior contribuição ao risco. Assim, valores próximos de 0 indicam terrenos mais planos e valores próximos de 1 indicam terrenos mais inclinados, sendo a camada normalizada utilizada diretamente na etapa de integração multicritério.

4.3.5 Altitude

Os dados de altitude foram obtidos a partir do Modelo Digital de Elevação (MDE) SRTM (*Shuttle Radar Topography Mission*), por meio do *dataset* “USGS/SRTMGL1_003”, o qual possui resolução espacial de 30 metros. Inicialmente, a imagem foi recortada para a área de estudo e, em seguida, foram extraídos os valores mínimo (Alt_{min}) e máximo (Alt_{max}) de elevação dentro do município utilizando o redutor *minMax()*.

Com base nesses parâmetros, a altitude foi padronizada para uma escala adimensional [0,1] por normalização do tipo min-max:

$$Alt_{esc} = \frac{Alt - Alt_{min}}{Alt_{max} - Alt_{min}} \quad (\text{Equação 12})$$

Na etapa seguinte, adotou-se a lógica de que altitudes mais baixas representam maior risco à ocorrência de incêndios florestais, conforme apontado por Nieto et al. (2012), Tian et al. (2013) e Dias (2023). Assim, aplicou-se a inversão da escala, de modo que o valor final utilizado na integração multicritério fosse:

$$Alt_{risco} = 1 - Alt_{esc} \quad (\text{Equação 13})$$

Dessa forma, na camada Alt_{risco} , 0 corresponde às áreas mais elevadas do município (menor contribuição ao risco) e 1 corresponde às áreas mais baixas (maior

contribuição ao risco), assegurando coerência com a lógica do índice final em que valores maiores indicam maior suscetibilidade.

4.3.6 Orientação das Encostas (aspecto)

A orientação das encostas (aspecto) também foi derivada a partir do Modelo Digital de Elevação (MDE) SRTM (*Shuttle Radar Topography Mission*), por meio do *dataset* “USGS/SRTMGL1_003”, utilizando a função *ee.Terrain.aspect()*, que calcula o azimuth da inclinação dominante de cada pixel, em graus, com valores variando de 0° a 360°. O valor 0° correspondendo ao norte geográfico, e os ângulos aumentando no sentido horário.

Em seguida, os valores de orientação foram classificados em cinco categorias de acordo com a proposta metodológica de Dias (2023), que agrupa as direções com base na exposição solar e influência no risco de incêndios florestais para regiões do hemisfério sul. A classificação foi implementada com a função *expression()*, da seguinte forma:

Quadro 3 – Classificação da Orientação das Encostas

Intervalo de Azimute (graus)	Direção Cardinal	Classe Numérica	Descrição Simplificada
337,5° a 360° e 0° a 22,5°	Norte	5	Maior influência solar
292,5° a 337,5°	Noroeste	4	Moderada influência solar
247,5° a 292,5°	Oeste	4	Moderada influência solar
67,5° a 112,5°	Leste	2	Baixa influência solar
22,5° a 67,5°	Nordeste	3	Média influência solar
112,5° a 157,5°	Sudeste	2	Alta influência solar
157,5° a 202,5°	Sul	1	Baixa influência solar
202,5° a 247,5°	Sudoeste	1	Baixa influência solar

Fonte: Adaptado de Dias (2023).

Após a reclassificação, a classe numérica (variando de 1 a 5) foi convertida para uma escala adimensional $[0,1]$ por meio da expressão *aspectClass.subtract(1).divide(4)*, assegurando proporcionalidade entre as classes. Nessa padronização, a classe 1 passa a corresponder a 0 (menor contribuição ao risco) e a classe 5 passa a corresponder a 1 (maior contribuição ao risco), de modo que valores próximos de 0 indicam menor suscetibilidade associada ao aspecto e valores próximos de 1 indicam maior suscetibilidade, mantendo a coerência com a integração multicritério do índice final (em que maiores valores representam maior risco).

4.4 PROCESSO DE ANÁLISE HIERÁRQUICA

Após a definição das variáveis, procedeu-se à construção da Matriz de Comparações de Julgamentos do método AHP, a fim de atribuir pesos relativos a cada fator com base em sua influência no risco de incêndios florestais. Para facilitar os cálculos dos vetores de prioridade e dos índices de consistência, utilizou-se a calculadora AHP disponível em <https://bpmsg.com/ahp/ahp-calc.php?lang=pt> (Gopel, 2018). O resultado encontra-se na Tabela 2.

Tabela 2 – Matriz de Comparação de Julgamentos e Pesos

	Precipitação	Temp.	NDVI	Declividade	Orientação das Encostas	Altitude
Precipitação	1	3	4	8	8	9
Temperatura	1/3	1	1	7	7	7
NDVI	1/4	1	1	8	8	8
Declividade	1/8	1/7	1/8	1	2	4
Orientação das Encostas	1/8	1/7	1/8	1/2	1	4
Altitude	1/9	1/7	1/8	1/4	1/4	1
Pesos	0.445	0.213	0.225	0.052	0.042	0.023

Fonte: Os autores (2025).

A matriz gerada apresentou um autovalor principal ($\lambda_{\max}$) de 6,608, resultando em um Índice de Consistência (IC) de 0,1216. Com base nesses valores, foi obtida

uma Razão de Consistência (RC) de 0,096. Considerando que, conforme proposto por Saaty (1980), valores de RC inferiores a 0,1 indicam um nível de inconsistência aceitável, não foi necessária a reavaliação da matriz. Isso assegura que os pesos atribuídos aos fatores apresentam coerência lógica e confiabilidade dentro do modelo multicritério.

Com base nos pesos definidos pelo método AHP e as variáveis previamente tratadas – normalizadas e, quando necessário, invertidas –, foi realizada a integração dos dados para gerar o mapa de risco de incêndios florestais. O cálculo foi realizado a partir de uma combinação linear ponderada, na qual cada variável foi multiplicada pelo respectivo peso atribuído no processo de análise hierárquica, conforme a Equação 14:

Equação 14

$$Risco = (Precipitação * 0,445) + (NDVI * 0,225) + (Temperatura * 0,213) + (Declividade * 0,052) + (Orientação das encostas * 0,042) + (Altitude * 0,023)$$

Essa expressão foi aplicada a cada pixel da imagem, resultando em um novo *raster* denominado "riscoIncendio", no qual os valores mais altos indicam maior risco de incêndios florestais.

4.5 IMPLEMENTAÇÃO DO PRODUTO TÉCNICO

O produto final representa uma síntese espacial do modelo multicritério, permitindo a identificação e a visualização das áreas de maior risco de incêndios florestais no município de Uruçuí. Sua implementação foi realizada no ambiente do GEE, em linguagem JavaScript, com base no *raster* contínuo denominado "riscoIncendio", resultante da integração ponderada das variáveis ambientais selecionadas. O código encontra-se disponível para consulta e reprodução por meio do seguinte link: <https://code.earthengine.google.com/7a595e4f183d5e925ebfaaba1b5517e9>. Além disso, visando ampliar a transparência e a possibilidade de reutilização do produto técnico-tecnológico, o script também foi hospedado em ambiente GitHub, podendo ser acessado em: <https://github.com/eng-luiz-eduardo/Script-de-risco-a-incendios-florestais-urucui>.

Para a visualização cartográfica do risco, o índice contínuo final foi convertido para percentual, originando a variável 'riscoPercentual', com valores variando de 0 a 100. A representação contínua desse índice no ambiente do Google Earth Engine foi realizada com parâmetros fixos de visualização, adotando-se os valores mínimo igual a 0 e máximo igual a 100, associados a uma paleta contínua predefinida em gradação crescente de cores. Essa padronização permitiu uma leitura visual uniforme do risco no território analisado e facilitou a interpretação comparativa dos valores do índice. Adicionalmente, foram calculados os valores mínimo e máximo do índice contínuo e do risco percentual por meio da função *reduceRegion()*, com a finalidade de apoio à conferência estatística e à interpretação dos resultados no painel e no console, sem interferir diretamente na definição da escala de visualização do mapa.

Posteriormente, foi utilizada a ferramenta de Inteligência Artificial Generativa *Codex/OpenAI* para a refatoração do código, com organização do layout da interface e incorporação de recursos adicionais de apresentação no ambiente do GEE. Todas as modificações incorporadas ao script foram revisadas e avaliadas, de modo a preservar a concepção metodológica da pesquisa, a seleção das variáveis, a definição dos pesos e a lógica multicritério adotada.

Além da exibição contínua do índice, foi incluída uma classificação temática do risco em quatro classes, com a finalidade de facilitar a leitura cartográfica do produto final. Essa classificação foi estruturada com base em faixas percentuais do índice e organizada conforme apresentado no Quadro 4.

Quadro 4 – Classes temáticas do índice de risco

Classe	Faixa do índice (%)	Interpretação
Q1	0–25	Risco baixo
Q2	25–50	Risco moderado
Q3	50–75	Risco alto
Q4	75–100	Risco muito alto

Fonte: Os autores (2026).

Adicionalmente, foi incorporado ao produto um painel lateral esquerdo para apoio à interpretação do mapa. Na seção 'Base temporal', foram apresentadas as datas de referência das variáveis dinâmicas utilizadas na execução do script, incluindo a data mais recente da temperatura de superfície, o intervalo temporal considerado para a precipitação acumulada e a janela temporal adotada para o cálculo do NDVI.

Esse recurso permite ao usuário identificar os recortes temporais associados ao processamento realizado em cada execução.

Na seção 'Estrutura do modelo', foram apresentados os pesos atribuídos às variáveis ambientais conforme definidos pelo método AHP, possibilitando a visualização sintética da contribuição relativa de cada fator na composição do índice final. Em seguida, a seção 'Legenda temática' foi adicionada para apresentar as classes do índice de risco e suas respectivas interpretações qualitativas, favorecendo a leitura cartográfica do produto.

Também foi incorporado ao painel um mecanismo de consulta pontual por clique, permitindo a obtenção, em local específico do mapa, dos valores do índice final e das variáveis normalizadas que o compõem. Para o ponto selecionado, são exibidas as coordenadas geográficas, o valor do índice final, o risco percentual, a classe temática correspondente e os valores normalizados de precipitação invertida, temperatura, NDVI invertido, declividade, aspecto e altitude. Esse recurso permite detalhar, em escala pontual, a composição do risco representado cartograficamente.

Adicionou-se ao painel um histograma de distribuição do índice, calculado a partir da imagem do risco percentual para toda a área do município. Esse gráfico apresenta a frequência dos valores do índice no território analisado, permitindo uma leitura complementar da distribuição espacial do risco e de sua concentração relativa nas diferentes faixas percentuais.

Ao final da execução, o script realiza a exportação automática dos produtos gerados para o Google Drive do usuário por meio da função *Export.image.toDrive()*. São produzidos, como saídas principais, o *raster* do índice contínuo de risco em percentual e o *raster* correspondente às classes temáticas do índice de risco. A exportação é efetuada com definição prévia da pasta de destino, nome dos arquivos, sistema de coordenadas, resolução espacial e delimitação da área de estudo, permitindo que os resultados sejam armazenados em formato compatível com sua posterior utilização em ambiente SIG, elaboração de mapas e apoio à tomada de decisão.

4.6 VALIDAÇÃO DO MÉTODO


Para a validação do mapa de risco, considerou-se o ano de 2024 como referência. Em cada dia desse período foi gerado, no GEE, um mapa do índice de

risco de incêndios para o município e, a partir dele, registrou-se um arquivo CSV (separado por vírgulas) para posterior tratamento.

Com o índice diário calculado, adotou-se a estratégia de classificação por quartis adotada por Sánchez et al. (2021), na qual os valores são divididos em quatro classes com intervalos iguais de 25%. Assim, para cada data, estimaram-se os percentis 25, 50 e 75 da distribuição do *raster* no interior do município (q25, q50 e q75) e o mapa foi reclassificado em quatro classes ordenadas: Q1 (os 25% dos pixels com menor risco, $\text{risco} \leq q25$), Q2 ($q25 < \text{risco} \leq q50$), Q3 ($q50 < \text{risco} \leq q75$) e Q4 (os 25% dos pixels com maior risco, $\text{risco} > q75$), conforme a Figura 2.

Tal procedimento fornece limiares definidos com base nos quartis da distribuição diária do índice, produzindo classes relativas de risco adaptadas à variabilidade temporal do período analisado, permitindo interpretação flexível dos resultados em diferentes condições sazonais.

Figura 2 – Quartis do Índice de Risco (diário)



Fonte: Os autores (2025).

Para cada data, registraram-se em arquivo CSV os limiares q25, q50 e q75, bem como o valor contínuo do índice de risco associado aos focos utilizados na validação. Essa estrutura permitiu organizar, em base tabular, os resultados diários necessários à análise estatística do desempenho do método ao longo do ano.

A opção por dividir o risco em quartis deve-se a duas razões principais. Primeiro, é que, considerando a disparidade de classificação de risco a incêndios sob a perspectiva de uma mesma variável, como a classificação metodológica de Dias (2023) e Prudente (2016), esse critério se ajusta automaticamente à sazonalidade e às mudanças de escala entre dias: os limiares derivam da distribuição do próprio índice em cada data, evitando-se impor cortes absolutos e arbitrários que poderiam ser inadequados em períodos secos ou chuvosos.

Segundo, os quartis oferecem um esquema simples que facilita a validação com dados de ocorrência, podendo utilizar como base a faixa superior da distribuição diária do risco, nesse caso a Q4, a porcentagem de focos que incidem sobre ela, e a porcentagem de área que o Q4 representa no município.

4.6.1 Focos de calor VIIRS

Para a validação empírica, utilizaram-se os focos de calor detectados pelo sensor VIIRS (*Visible Infrared Imaging Radiometer Suite*), provenientes dos satélites em órbita polar Suomi NPP e NOAA-20/JPSS-1. Esses sensores fornecem detecções diárias de queimadas com resolução espacial de 375 m, associadas a atributos como a confiança da detecção. Cada foco identificado foi relacionado ao mapa diário de risco correspondente à sua data de ocorrência, recebendo o valor contínuo do índice de risco e a respectiva classe quartílica (Q1 a Q4) do pixel em que se localizava.

Considerando-se que a base de validação foi composta por registros oriundos de dois sensores distintos, aplicou-se uma etapa complementar de deduplicação espaço-temporal, com o objetivo de reduzir a possibilidade de dupla contagem de focos muito próximos no espaço e no tempo, potencialmente associados ao mesmo evento de fogo. Esse processo de deduplicação espaço-temporal já foi adotado por outros estudos que usando dados do VIIRS: Fu et al. (2020), Lyu et al. (2026).

Para viabilizar esse procedimento, cada registro foi exportado com data, horário completo de aquisição, coordenadas geográficas e identificador único, permitindo sua ordenação cronológica e processamento posterior em JupyterLab.

A deduplicação foi realizada mediante o agrupamento de registros que apresentassem, simultaneamente, diferença temporal de até 60 minutos e distância espacial máxima de 750 m. Esses parâmetros foram adotados como critério operacional para identificação de detecções provavelmente redundantes entre os sensores utilizados.

Após a deduplicação, os focos foram organizados em base tabular contendo, para cada ocorrência, a data, o sensor de origem, as coordenadas geográficas, o nível de confiança da detecção, o valor contínuo do índice de risco, a classe quartílica correspondente e os limiares diários q25, q50 e q75. Essa estrutura permitiu a

realização de análises estatísticas voltadas à avaliação do desempenho do método, especialmente no que se refere à distribuição dos focos entre as classes Q1, Q2, Q3 e Q4 ao longo do ano de 2024.

Para quantificar a priorização espacial do mapa, de forma complementar extraiu-se a Razão de Eficiência (RE) dos quartis, definida da seguinte forma:

$$RE_i = \frac{PF_i}{PA_i} \quad (\text{Equação 15})$$

Em que:

RE_i = razão de eficiência da classe i ,

PF_i = percentual de focos na classe i ,

PA_i = percentual de área da classe i .

Valores $RE_i > 1$ a classe concentra mais focos do que seria esperado pela sua participação em área; $RE_i = 1$ proporção de focos equivalente à proporção de área; $RE_i < 1$ a classe concentra menos focos do que seria esperado pela sua participação em área.

4.6.2 Mapas-sínteses dos meses críticos

Para representar, em escala mensal, a persistência espacial das áreas enquadradas nas faixas superiores do índice de risco, foi elaborada uma composição cartográfica sintética para os meses de agosto, setembro e outubro de 2024, correspondentes ao período de maior concentração de focos de calor no município.

No GEE, o índice diário de risco foi recalculado para cada dia dos meses selecionados. Em seguida, os valores diários do *raster* foram reclassificados com base nos quartis do índice, sendo identificados os pixels pertencentes às classes superiores Q3 e Q4. A partir dessa classificação, foi gerada, para cada mês, uma imagem-síntese correspondente à frequência de permanência dos pixels em Q3+Q4, expressa em porcentagem de dias do mês. Assim, cada pixel passou a representar a proporção de dias em que permaneceu nas classes superiores do índice ao longo do respectivo mês.

Para fins de representação cartográfica e comparação visual entre os meses analisados, a recorrência mensal de Q3+Q4 foi organizada em quatro intervalos percentuais: 0–25%, 25–50%, 50–75% e 75–100% dos dias do mês. Esses intervalos permitiram distinguir, de forma padronizada, áreas com menor e maior persistência do risco elevado ao longo do período mensal.

Os *rasters* mensais foram exportados em formato GeoTIFF e finalizados no software QGIS, onde foram definidos a simbologia, a composição visual e os elementos cartográficos. Sobre essas superfícies, foram sobrepostos os focos de calor do sensor VIIRS previamente deduplicados e filtrados para cada mês.

De forma complementar, foi realizado um detalhamento espacial dos focos em relação a padrões de ocupação da paisagem, com apoio de imagens de satélite obtidas no QGIS por meio do plugin CBERS4A Downloader. Para isso, foram selecionadas imagens referentes ao intervalo compreendido entre o início e o fim de cada mês analisado, adotando-se o critério de cobertura máxima de nuvens de 10%. Essas imagens foram utilizadas como suporte visual na composição cartográfica, com o objetivo de auxiliar a interpretação qualitativa da distribuição dos focos em relação às áreas vegetadas e aos setores com diferentes padrões de ocupação do território.


5 RESULTADOS E DISCUSSÃO

5.1 CONSOLIDAÇÃO DA BASE DE VALIDAÇÃO

A validação do índice de risco de incêndios foi estruturada a partir da geração de 366 mapas diários do ano de 2024, correspondentes a cada dia do período analisado, e do levantamento dos focos de calor detectados pelo sensor VIIRS.

Inicialmente, a base de focos totalizou 37.620 registros brutos, e após a deduplicação espaço-temporal, a base foi reduzida para 1.417 focos deduplicados, evidenciando 36.203 registros fundidos, o que evidencia a elevada redundância presente no conjunto bruto.

Figura 3 - Número de focos brutos e focos deduplicados em 2024.




Fonte: Os autores (2026).

A expressiva redução entre o número inicial de registros e o total de focos remanescentes após a deduplicação demonstra que a utilização simultânea de diferentes sensores, embora amplie a capacidade de detecção, também pode introduzir redundâncias relevantes quando se pretende analisar a distribuição efetiva dos eventos de fogo. A deduplicação espaço-temporal já foi necessária em outros estudos que observaram a duplicidade dos dados VIIRS (Fu et al., 2020).

Em termos temporais, a base consolidada evidenciou forte concentração sazonal das ocorrências, com destaque para os meses de agosto, setembro e outubro, que responderam pela maior parte dos focos registrados em 2024.

Gráfico 2 – Distribuição mensal dos focos em Uruçuí – PI (2024)



Fonte: Os autores (2026).


O mês de setembro apresentou o maior total, com 478 ocorrências, seguido por agosto, com 360, e outubro, com 242. Em conjunto, esses três meses concentraram aproximadamente 76,2% de todos os focos deduplicados analisados no

período, evidenciando a forte influência da sazonalidade sobre a dinâmica do fogo no município de Uruçuí-PI.

Esse comportamento temporal já foi observado em outros estudos dessa temática em áreas do cerrado. Goulart, Morelli e Setzer (2011) observaram maior concentração de focos de calor em agosto, setembro e outubro nas Unidade de Conservação do Mato Grosso. Já Lima (2018) observou pico de focos de calor concentrado no mês de setembro em todo o bioma Cerrado no Brasil.

Com os dados, cada foco foi relacionado ao valor do índice de risco do pixel correspondente e, conforme o procedimento metodológico adotado, à sua respectiva classe quartílica diária. A distribuição anual das ocorrências mostrou que 80 focos, correspondentes a 5,65% do total, incidiram em Q1; 238 focos, equivalentes a 16,80%, em Q2; 733 focos, ou 51,73%, em Q3; e 366 focos, correspondentes a 25,83%, em Q4, conforme Gráfico 3.

Gráfico 3 – Focos de calor VIIRS por classe de risco (2024)




Fonte: Os autores (2026).

Esses resultados indicam que a maior parte dos registros se concentrou nas classes superiores do índice, uma vez que 77,56% dos focos deduplicados ocorreram em Q3 e Q4, o que sugere coerência entre a hierarquização espacial produzida pelo modelo e a distribuição observada das ocorrências de fogo ao longo do ano. Em outros trabalhos a distribuição espacial também é fortemente concentrada nas classes mais

altas de suscetibilidade, utilizando modelos de quartis e semelhantes (Sánchez et al., 2021; Eslami et al., 2021).

Quando se compara a proporção de focos com a proporção de área acumulada por classe (Gráfico 4), observa-se um comportamento igualmente relevante. Em termos de área anual acumulada em km².dia, as classes representaram 4,31% em Q1, 20,73% em Q2, 53,50% em Q3 e 21,47% em Q4.

Gráfico 4 – Distribuição da área (km².dia) por classe de risco em 2024.



Fonte: Os autores (2026).

A classe Q4, correspondente à faixa de maior risco relativo, concentrou 25,83% dos focos em 21,47% da área acumulada, resultando em razão de eficiência igual a 1,20. Esse resultado indica enriquecimento relativo das ocorrências na classe mais alta do índice, isto é, uma concentração de focos acima do que seria esperado caso a distribuição fosse proporcional apenas à área ocupada por essa classe. Esse resultado corrobora com outros estudos, como Sivrikaya e Küçük (2022), que observaram que 85% dos pontos de ignição estão em áreas de risco extremo ou alto, embora essas classes ocupem apenas parte da área total, na região leste do Mediterrâneo, na Turquia.

Já a classe Q2 apresentou razão de eficiência de 0,81, revelando participação inferior à sua proporção de área, enquanto Q3, apesar de concentrar o maior número absoluto de focos, apresentou valor próximo da proporcionalidade, com razão de

eficiência de 0,97, o que se explica por ser também a classe com maior extensão acumulada ao longo do ano.

Nesse sentido, a classe Q3 funcionou como a principal faixa de transição operacional do risco, ao concentrar ampla área acumulada e grande volume de ocorrências, enquanto Q4 se destacou mais pela eficiência relativa do que pela massa absoluta de focos.

Tabela 3 – Distribuição anual dos focos, área acumulada e razão de eficiência por classe quartílica do índice de risco em Uruçuí (2024)

Classe quartílica	Nº de focos	% de focos	Área acumulada (km².dia)	% de área acumulada	Razão de eficiência
Q1	80	5,65	132.629,40	4,31	1,31
Q2	238	16,80	638.207,80	20,73	0,81
Q3	733	51,73	1.647.172,00	53,50	0,97
Q4	366	25,83	660.911,30	21,47	1,20
Total	1.417	100,00	3.078.920,50	100,00	—

Fonte: Os autores (2026).

Esses achados sugerem que o índice apresentou melhor desempenho como ferramenta de hierarquização espacial do risco do que como classificador rígido de ocorrência e não ocorrência de fogo. Ou seja, o modelo mostrou capacidade de ordenar o território segundo níveis relativos de suscetibilidade, com destaque para a classe Q4, que concentrou 25,83% dos focos em 21,47% da área acumulada, resultando em razão de eficiência de 1,20.

A classe Q1 também apresentou razão de eficiência superior a 1,00 (1,31). Assim, mais do que indicar equivalência entre as classes extremas, esse comportamento sugere que a distinção entre extremos e classes intermediárias foi mais nítida do que a separação interna entre todos os níveis do índice. Tal interpretação é compatível com Güngöroğlu et al. (2024), que observaram melhor correspondência entre mapas de risco pré-fogo e ocorrência ou severidade observada nas classes extremas, com redução de desempenho nas classes intermediárias.


De forma semelhante, Aires, Angelini e Danelichen (2024) verificaram que a maior parte dos focos se concentrou nas classes moderada e alta, evidenciando boa

capacidade de hierarquização espacial, embora a presença de focos em classes inferiores impeça o uso do índice como classificador rígido. Nesse sentido, os resultados obtidos em Uruçuí-PI reforçam que o modelo é mais adequado para priorização territorial do monitoramento e das ações preventivas do que para uma leitura bipartida de presença e ausência de fogo.

Cabe destacar que os percentuais anuais de área por quartil não reproduzem, necessariamente, a divisão teórica de 25% para cada classe. Isso ocorre porque os limiares quartílicos foram recalculados diariamente e a síntese anual foi expressa em km².dia, incorporando a variabilidade temporal do índice ao longo de todo o ano. Assim, a análise anual não deve ser interpretada como uma simples repartição fixa do território, mas como a expressão acumulada da dinâmica espaço-temporal do risco. Nesse sentido, a maior concentração de focos em Q3 e, sobretudo, o desempenho relativo de Q4 reforçam a consistência do índice como instrumento de priorização espacial.

Para tornar essa relação mais evidente, a comparação entre o percentual de focos e o percentual de área ocupada por cada classe (Gráfico 5) mostra que a classe Q4 apresenta maior participação relativa de ocorrências do que de área, indicando enriquecimento dos focos na faixa de maior risco.

Gráfico 5 – Comparação entre o percentual de focos e o percentual de área acumulada por classes em Uruçuí (2024)



Fonte: Os autores (2026).

Em sentido oposto, as classes Q2 e Q3 apresentaram percentuais de focos inferiores à sua participação espacial acumulada, embora com intensidades distintas: em Q2 essa sub-representação foi mais pronunciada, ao passo que em Q3 os valores permaneceram muito próximos da proporcionalidade.


Esse contraste reforça a interpretação de que o modelo, ainda que não concentre a maior parte absoluta dos focos exclusivamente na classe mais alta, consegue indicar com maior eficiência relativa os setores mais críticos do território.

5.2 MAPAS-SÍNTESES DOS MESES CRÍTICOS

Para a representação visual do índice de risco, foram utilizados os meses de agosto, setembro e outubro de 2024, pois nesse intervalo concentrou-se a maior parte dos focos de calor registrados na nossa base. A soma desses meses registrou 1.080 ocorrências, o que corresponde a 76,2% de todos os focos identificados no ano. Logo esses três meses representa, o período mais crítico na dinâmica do fogo em Uruçuí, constituindo, portanto, o recorte temporal mais adequado para a elaboração de produtos cartográficos sintéticos voltados à análise da coerência espacial entre a recorrência do risco e a distribuição dos focos observados.

Esses meses apresentaram a seguinte distribuição dos focos entre as classes quartílicas do índice de risco (Gráfico 6):

Gráfico 6 – Distribuição dos focos por classe quartílica (agosto, setembro e outubro)



Fonte: Os autores (2026).

Em agosto, verificou-se que 25 focos (6,94%) incidiram em Q1, 41 (11,39%) em Q2, 175 (48,61%) em Q3 e 119 (33,06%) em Q4. Em setembro, mês com maior número absoluto de ocorrências, registraram-se 25 focos (5,23%) em Q1, 65 (13,60%) em Q2, 252 (52,72%) em Q3 e 136 (28,45%) em Q4. Já em outubro, foram observados 10 focos (4,13%) em Q1, 62 (25,62%) em Q2, 126 (52,07%) em Q3 e 44 (18,18%) em Q4.

Esses resultados evidenciam, de forma consistente, que a maior parte dos focos dos meses críticos se concentrou em Q3, e não na classe extrema Q4. Em agosto, Q3 reuniu praticamente metade das ocorrências mensais, enquanto Q4 respondeu por cerca de um terço. Em setembro, esse comportamento se manteve, com Q3 concentrando a maior parcela dos focos e Q4 ocupando a segunda posição. Em outubro, embora Q3 também tenha permanecido como a classe predominante, observou-se redução da participação de Q4 e aumento relativo de Q2, indicando uma distribuição menos concentrada na classe mais alta do índice quando comparada aos dois meses anteriores.


Quando se somam as classes superiores do índice, observa-se que Q3+Q4 concentraram 81,67% dos focos em agosto, 81,17% em setembro e 70,25% em outubro. Esses percentuais reforçam que, nos meses mais críticos do ano, o índice apresentou melhor desempenho ao destacar as faixas superiores de risco, ainda que a concentração das ocorrências não tenha se restringido exclusivamente à classe máxima.

Tal comportamento confirma a interpretação já apontada na análise anual, segundo a qual o modelo se mostra mais consistente como ferramenta de hierarquização espacial da suscetibilidade ao fogo do que como classificador rígido de ocorrência e não ocorrência.

Considerando que os focos dos meses críticos se concentraram majoritariamente em Q3 e Q4, optou-se por construir os mapas-síntese mensais com base na frequência de permanência dos pixels nas classes superiores do índice (Q3+Q4). Essa escolha permitiu representar de forma mais fiel a distribuição espacial do risco elevado observada na validação, preservando a coerência entre a análise estatística e a comunicação cartográfica dos resultados.

A Figura 4 apresenta essa composição cartográfica, na qual cada painel mensal expressa a porcentagem de dias em que os pixels permaneceram nas classes superiores do índice, com sobreposição dos focos VIIRS deduplicados correspondentes ao respectivo mês.


Figura 4 – Mapas-síntese da frequência de permanência em Q3+Q4 e distribuição dos focos VIIRS em agosto, setembro e outubro



Fonte: Os autores (2026).

A análise da distribuição dos focos em relação às faixas de recorrência mensal de Q3+Q4 revelou um comportamento importante para a interpretação do Gráfico 7.

Gráfico 7 – Distribuição dos focos e da área por faixa de recorrência mensal (Q3+Q4)



Fonte: Os autores (2026).

Em agosto, observou-se que 184 focos (51,11%) ocorreram na faixa de 0–25% de recorrência, enquanto 176 focos (48,89%) incidiram na faixa de 75–100%. Em setembro, esse padrão tornou-se ainda mais evidente, com 295 focos (61,72%) na faixa de 0–25% e 183 focos (38,28%) em 75–100%. Em outubro, verificou-se distribuição um pouco menos polarizada, com 142 focos (58,68%) em 0–25%, 15 focos (6,20%) em 25–50% e 85 focos (35,12%) em 75–100% de recorrência mensal.

Embora uma parcela expressiva das ocorrências tenha se concentrado em áreas de baixa recorrência mensal de Q3+Q4, isso não invalida o desempenho do método, mas evidencia a diferença entre a lógica temporal do evento e a lógica temporal da síntese cartográfica. Conforme apontam Jiménez-Ruano et al. (2019), índices diários de perigo de incêndio apresentam forte relação com a dinâmica mensal de ocorrências, inclusive com defasagens temporais, indicando que anomalias meteorológicas de curto prazo podem deflagrar incêndios mesmo em contextos nos quais a persistência do risco em escala mais agregada não se mostra tão expressiva. Nessa perspectiva, um foco pode ocorrer em um pixel que, no dia do evento, apresentou condição favorável à ignição ou propagação, mas que, no conjunto do mês, permaneceu poucas vezes nas classes superiores do índice.


Özcan et al. (2024) ressaltam que mapas de risco de incêndios tendem a apresentar melhor desempenho quando utilizados para priorizar áreas por risco relativo do que como classificadores rígidos de ocorrência e não ocorrência, o que converge diretamente com os resultados encontrados em Uruçuí-PI.

De modo complementar, Benali et al. (2023) destacam que avaliações de risco que articulam perigo, exposição e vulnerabilidade têm maior utilidade para orientar

prioridades de mitigação e alocação de recursos em escala local do que para prever eventos exatos de incêndio. Assim, a presença de focos tanto em áreas de baixa recorrência mensal quanto em áreas de alta persistência do risco sugere que a dinâmica do fogo no município resulta da interação entre condições ambientais favoráveis, variabilidade temporal de curto prazo e fatores antrópicos de ignição.


Sob essa perspectiva, a leitura da composição cartográfica sugere que a distribuição dos focos nos meses críticos não se associa apenas às áreas de maior persistência mensal do risco, mas também à configuração territorial do município. Em análise visual exploratória, observou-se que parte expressiva dos focos localizados em setores de baixa recorrência mensal de Q3+Q4 parece coincidir com áreas ainda cobertas por vegetação, e não necessariamente com os compartimentos mais intensamente ocupados por cultivos de commodities. Embora essa constatação não tenha sido objeto de quantificação específica nesta etapa da pesquisa, ela indica que a dinâmica espacial do fogo em Uruçuí-PI pode refletir não apenas a persistência das condições ambientais favoráveis, mas também a estrutura do uso e cobertura da terra.

Figura 5 – Detalhamento espacial dos focos em relação a padrões de ocupação da paisagem, no mês de agosto de 2024.




Fonte: Os autores (2026).

Figura 6 – Detalhamento espacial dos focos em relação a padrões de ocupação da paisagem, no mês de setembro de 2024.



Fonte: Os autores (2026)

Figura 7 – Detalhamento espacial dos focos em relação a padrões de ocupação da paisagem, no mês de outubro de 2024.



Fonte: Os autores (2026).

Esse achado é compatível com a literatura que aponta a influência das transformações territoriais sobre os padrões de fogo no Cerrado. Abreu et al. (2022)

destacam que a expansão das terras agrícolas está correlacionada com o aumento da frequência de incêndios, uma vez que a conversão da terra altera a disponibilidade de combustível e amplia as fontes de ignição. Tal interpretação é relevante para o contexto de Uruçuí-PI, onde a dinâmica recente de ocupação agropecuária e de conversão da paisagem tende a produzir mosaicos territoriais heterogêneos, formados por áreas agrícolas, remanescentes vegetados e setores em transição de uso.

Desse modo, os resultados apresentados reforçam que o produto desse relatório pode ser utilizado como instrumento de priorização espacial do risco em locais que podem ocorrer focos de incêndios. Ainda assim, a observação visual da associação entre parte dos focos e áreas vegetadas aponta para uma questão relevante a ser aprofundada em estudos posteriores: o papel específico do uso e cobertura da terra na explicação dos focos situados em áreas de baixa recorrência mensal de Q3+Q4.

5.3 PRODUTO TÉCNICO-TECNOLÓGICO DERIVADO DA PESQUISA

Nessa seção será apresentado o resultado dessa pesquisa, um produto técnico-tecnológico voltado a operacionalização da metodologia proposta. Trata-se de um script desenvolvido no ambiente Google Earth Engine, estruturado para realizar, de forma automatizada, a aquisição, o processamento e a integração das variáveis climáticas, topográficas e vegetacionais utilizadas na composição do índice de risco de incêndios florestais para o município de Uruçuí-PI.

5.3.1 Descrição do script e fluxo operacional

O produto técnico desenvolvido nesta pesquisa consiste em um script em linguagem JavaScript implementado no Google Earth Engine, estruturado para automatizar as principais etapas de construção do índice de risco de incêndios florestais para o município de Uruçuí-PI.

Em termos operacionais, o script foi organizado em blocos funcionais que refletem a sequência lógica do processamento no GEE, desde a definição da área de estudo até a exportação do *raster* final. Segue abaixo o Quadro 5 com a fluxo operacional do script.

Quadro 5 – Estrutura Operacional do Script

Bloco do script	Função no processamento
Configuração inicial	Define a área de interesse correspondente ao limite municipal de Uruçuí-PI, centraliza o mapa e configura os controles básicos da interface no ambiente do Google Earth Engine.
Funções auxiliares	Reúne funções de apoio ao processamento, incluindo normalização min-max, resumo estatístico das variáveis, formatação numérica e elementos visuais auxiliares da interface.
Precipitação – CHIRPS	Seleciona a imagem mais recente disponível, acumula a precipitação em 15 dias, inverte sua lógica de influência e gera a camada padronizada de risco associada à precipitação.
Temperatura de superfície – MODIS	Integra produtos Terra e Aqua, converte a temperatura de Kelvin para °C, calcula a composição principal em 7 dias e utiliza uma janela complementar de 30 dias para preenchimento de lacunas.
NDVI – Sentinel-2	Aplica máscara de qualidade com base na camada SCL, produz composições temporais de 30 e 60 dias, calcula o NDVI e inverte sua lógica para representar maior risco em áreas com menor vigor vegetativo.
Topografia – SRTM	Deriva altitude, declividade e orientação das encostas, realizando a padronização e a adequação de cada variável à lógica de suscetibilidade adotada no modelo multicritério.
Pesos AHP	Armazena os pesos definidos pelo Processo de Análise Hierárquica e prepara a combinação linear ponderada das variáveis ambientais.
Índice final de risco	Integra todas as variáveis padronizadas em um <i>raster</i> contínuo denominado “riscoIncendio”, posteriormente convertido em percentual para fins de visualização temática.

Classificação temática	Organiza o índice percentual em quatro classes de exibição cartográfica: Q1 – risco baixo; Q2 – risco moderado; Q3 – risco alto; Q4 – risco muito alto.
Camadas de visualização	Estrutura as camadas exibidas no mapa, incluindo relevo sombreado, índice contínuo de risco, classes temáticas do índice, limite municipal e variáveis auxiliares para consulta visual.
Painel lateral de interface	Organiza informações textuais e visuais de apoio à leitura do produto, incluindo base temporal, estrutura do modelo, legenda temática, consulta pontual e histograma de distribuição do índice.
Base temporal	Apresenta, no painel lateral, as datas e janelas temporais utilizadas no processamento das variáveis dinâmicas, como temperatura, precipitação acumulada e NDVI.
Estrutura do modelo	Exibe os pesos das variáveis empregados na composição do índice final, permitindo visualização sintética da contribuição relativa de cada fator.
Legenda temática	Apresenta as classes do índice de risco e suas respectivas denominações qualitativas, favorecendo a interpretação cartográfica imediata do produto.
Consulta pontual por clique	Permite a inspeção local do modelo, exibindo no painel lateral as coordenadas do ponto selecionado, o valor do índice final, o risco percentual, a classe temática correspondente e os valores normalizados das variáveis naquele local.
Histograma de distribuição	Gera gráfico com a frequência dos valores do índice percentual em toda a área do município, permitindo leitura complementar da distribuição espacial do risco.
Exportação dos produtos	Realiza a exportação automática para o Google Drive do usuário do <i>raster</i> contínuo do índice em percentual e do <i>raster</i> classificado em classes temáticas.

Resumo no console	Exibe informações de conferência da execução, incluindo datas de referência, janelas temporais, estatísticas das variáveis e amplitude do índice final.
--------------------------	---

Fonte: Os autores (2026)

Essa estrutura favorece a reprodutibilidade da metodologia, a conferência das etapas executadas e a adaptação futura do produto para outras áreas de interesse.

5.3.2 Potencial de aplicação prática

Ao automatizar a obtenção, o tratamento e a integração de variáveis ambientais relevantes à suscetibilidade ao fogo, o produto desenvolvido nessa pesquisa permite a geração padronizada de mapas de risco, reduzindo a dependência de procedimentos manuais extensos e favorecendo a atualização contínua das informações espaciais. Dessa forma, o produto se configura como uma ferramenta operacional passível de utilização por instituições públicas e equipes técnicas envolvidas com a gestão territorial.

A utilidade desse tipo de produto encontra respaldo em estudos recentes que destacam a relevância dos mapas de risco de incêndios como instrumentos de apoio à tomada de decisão. Souza et al. (2025) ressaltam que a elaboração de mapas de risco de incêndios florestais constitui uma ferramenta valiosa, aplicável inclusive em escala municipal, desde que sejam consideradas as variáveis locais que influenciam o comportamento do fogo. Os autores destacam ainda que o investimento em políticas de informação representa uma das formas mais econômicas de evitar perdas maiores associadas a incêndios provocados por ações humanas.

No caso específico de Uruçuí-PI, a aplicação do script possibilita identificar, de forma espacializada, setores do território com maior propensão relativa à ocorrência de incêndios, o que pode subsidiar ações preventivas, definição de áreas prioritárias para monitoramento e direcionamento mais eficiente de esforços institucionais. Em termos práticos, os resultados gerados podem servir de apoio à atuação de secretarias municipais de meio ambiente, brigadas locais, defesa civil e demais órgãos ligados à prevenção e ao controle do fogo, contribuindo para o reconhecimento prévio de áreas mais sensíveis, sobretudo em períodos de maior criticidade sazonal.

Nessa mesma perspectiva, Souza (2022) destaca que metodologias voltadas à geração de mapas de risco podem atuar como ferramentas de apoio à tomada de decisão, permitindo identificar previamente áreas com maior vulnerabilidade ao fogo e, a partir disso, orientar a adoção de medidas preventivas e de combate. Entre essas medidas, o autor menciona ações como construção de aceiros, instalação de estruturas de apoio próximas às áreas mais suscetíveis e utilização de estratégias de manejo integrado do fogo.

De modo semelhante, Dias (2023) assinala que os mapas de risco de queimadas e incêndios podem espacializar satisfatoriamente as ameaças e vulnerabilidades de uma área, produzindo resultados promissores para a gestão e a prevenção em setores críticos. Segundo a autora, esse tipo de mapeamento contribui para melhorar a eficiência das medidas adotadas, otimizar a utilização de recursos financeiros e fornecer subsídios para definir prioridades entre áreas sujeitas à ignição e à propagação do fogo.

Outro aspecto relevante do produto é sua reprodutibilidade. Por ter sido estruturado em ambiente computacional de acesso remoto e com processamento em nuvem, o script pode ser reexecutado com relativa facilidade, desde que mantidas as bases de dados e os parâmetros estabelecidos. Essa característica amplia o alcance do produto, que pode ser replicado em outros municípios ou regiões com problemática semelhante, favorecendo sua utilização como instrumento de apoio ao planejamento ambiental em diferentes escalas.

6 CONSIDERAÇÕES FINAIS

Os resultados obtidos indicam que o índice proposto apresentou desempenho satisfatório como instrumento de hierarquização espacial da suscetibilidade ao fogo, permitindo identificar setores do território de Uruçuí mais propensos à ocorrência de incêndios em termos relativos. A validação realizada com focos de calor do sensor VIIRS ao longo do ano de 2024 mostrou que a maior parte das ocorrências se concentrou nas classes superiores do índice, especialmente em Q3 e Q4, o que confirma a coerência geral da modelagem proposta.

A análise dos meses críticos de agosto, setembro e outubro de 2024 reforçou essa interpretação. Os mapas-síntese mensais mostraram que a recorrência das

classes superiores do índice constituiu uma estratégia cartográfica adequada para representar a persistência espacial do risco elevado. Ao mesmo tempo, os resultados evidenciaram que os focos não ocorreram exclusivamente nas áreas de maior recorrência mensal, mas também em setores de baixa permanência em Q3+Q4, indicando que a dinâmica do fogo em Uruçuí-PI resulta da interação entre condições ambientais favoráveis, variabilidade temporal de curto prazo e fatores antrópicos de ignição. Assim, o estudo demonstrou que o índice é mais robusto quando interpretado como ferramenta de priorização territorial do que como previsor exato dos locais de ignição.

Sob a perspectiva do produto derivado da pesquisa, destaca-se como principal produto derivado da pesquisa o script desenvolvido em JavaScript no Google Earth Engine, disponibilizado em repositório digital e em apêndice. Trata-se de uma entrega aplicada, reprodutível e passível de atualização contínua, com potencial de uso por órgãos públicos, equipes técnicas e instituições ligadas ao monitoramento e à prevenção de incêndios florestais. Na prática, esse produto pode auxiliar a gestão ambiental municipal ao subsidiar a identificação prévia de áreas mais suscetíveis, favorecendo a orientação de ações preventivas, o planejamento territorial, a distribuição mais racional de equipes e equipamentos, bem como a alocação mais eficiente de recursos financeiros voltados ao combate e à mitigação dos incêndios.

A aplicação real desse índice em Uruçuí, assim como em outros municípios com territórios extensos, e por vezes com recursos operacionais limitados, como ocorre em diversas áreas do Cerrado, pode ajudar a hierarquizar setores críticos e definir prioridades de vigilância, prevenção e respostas ao fenômeno, assim como ações de fiscalização ambiental.

Apesar dos resultados alcançados, o estudo apresenta limitações que devem ser consideradas. A primeira delas refere-se ao fato de que o índice foi construído a partir de um conjunto de variáveis selecionadas com base na literatura, na disponibilidade e compatibilidade espacial a escala municipal com os dados do GEE. Nesse processo, foi priorizado fatores com maior consistência teórica e discriminação espacial para o recorte estudado, resultando assim, na não incorporação de variáveis importantes, como a distância a estradas, uso e ocupação do solo e velocidade dos ventos. A exclusão desses fatores, especialmente aqueles relacionados a

condicionantes antrópicos de ignição, reduz em parte a capacidade do modelo de captar a complexidade da dinâmica do fogo.

Diante dessas limitações, algumas proposições futuras se mostram relevantes. Recomenda-se o aprofundamento da análise mediante a incorporação de variáveis antrópicas complementares e o cruzamento do índice com bases de uso e cobertura da terra, de modo a investigar com maior precisão o papel da estrutura da paisagem na distribuição espacial dos focos em Uruçuí-PI. Embora a avaliação visual realizada nesta pesquisa sugira que parte das ocorrências em áreas de baixa recorrência mensal possa estar associada a setores ainda vegetados, essa hipótese não integrou o objetivo central da dissertação e, por isso, poderá ser melhor desenvolvida em estudos posteriores. Também se considera pertinente testar outras estratégias de agregação temporal do risco, bem como replicar o modelo em outros municípios do Cerrado, especialmente em áreas de fronteira agrícola, de modo a avaliar sua robustez e sua adaptabilidade em contextos territoriais distintos.

REFERÊNCIAS

- ABATZOGLOU, J. T.; WILLIAMS, A. P. Impact of anthropogenic climate change on wildfire across western US forests. **Proceedings of the National Academy of Sciences**, [s. l.], v. 113, n. 42, p. 11770-11775, 2016. DOI: <https://doi.org/10.1073/pnas.1607171113>.
- ABREU, M. C.; LYRA, G. B.; OLIVEIRA-JÚNIOR, J. F. de; SOUZA, A.; POBOČÍKOVÁ, I.; FRAGA, M. de S.; ABREU, R. C. R. Temporal and spatial patterns of fire activity in three biomes of Brazil. **Science of the Total Environment**, [s. l.], v. 844, p. 157138, 2022. DOI: <https://doi.org/10.1016/j.scitotenv.2022.157138>.
- AGUIAR, R. B. de; GOMES, J. R. de C. **Projeto cadastro de fontes de abastecimento por água subterrânea, estado do Piauí: diagnóstico do município de Uruçuí**. Fortaleza: CPRM - Serviço Geológico do Brasil, 2004.
- AIRES, L. S. da S.; ANGELINI, L. P.; DANELICHEN, V. H. de M. Estimating the risk of wildfires in the municipality of Rio Verde, Goiás State, Central Brazil. **Revista Brasileira de Ciências Ambientais**, [s. l.], v. 60, n. 1, p. 2006-2006, 2025. DOI: <https://doi.org/10.5327/z2176-94782006>.
- ALMEIDA, G. S. S.; MARIANO DA SILVA, E.; RODRIGUES DA SILVA, V. de P.; BARACUY DA CUNHA CAMPOS, J. H.; TAVARES SILVA, M. Performance of the Climate Hazards Group InfraRed Precipitation with Station data (CHIRPS) Model in the Northeast Region of Brazil. **Revista Brasileira de Geografia Física**, [s. l.], v. 17, n. 6, p. 4117-4130, 2024. DOI: 10.26848/rbgf.v17.6.p4396-4408. Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe/article/view/263595>. Acesso em: 18 set. 2025.
- ANABALÓN, A.; SHARMA, A. On the divergence of potential and actual evapotranspiration trends: an assessment across alternate global datasets. **Earth's Future**, [s. l.], v. 5, n. 9, p. 905-917, 2017. DOI: <https://doi.org/10.1002/2016ef000499>.
- ANDRADE, B. C. C. de. **Estimativa da evapotranspiração real via sensoriamento remoto**. 2018. Dissertação (Mestrado em Saneamento, Meio Ambiente e Recursos Hídricos) - Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2018.
- ANDRADE, G. S. **Análise de risco integrada à gestão de segurança de barragens**. 2021. Dissertação (Mestrado em Desenvolvimento de Tecnologia) - Instituto de Tecnologia para o Desenvolvimento, Curitiba, 2021.
- ARIAS-MUÑOZ, P.; CHUMA-POMASQUI, L.; CORONADO CACUANGO, P.; JÁCOME-AGUIRRE, G. Susceptibility to vegetation cover fires: an evaluation using multi-criteria and radio frequency methods (Cotacachi Cantón, Ecuador). **Cuadernos de Investigación Geográfica**, Logroño, v. 50, n. 1, p. 21-39, 2024. DOI: 10.18172/cig.5867. Disponível em: <https://publicaciones.unirioja.es/ojs/index.php/cig/article/view/5867>. Acesso em: 4 jul. 2025.

ARRUDA, V. L. da S. **Mapeamento de cicatrizes de áreas queimadas no Cerrado usando imagens Landsat, Google Earth Engine e Deep Learning**. 2021. 61 f. Dissertação (Mestrado em Ciências Florestais) - Universidade de Brasília, Brasília, 2021.

ASSIS, F. R. V. et al. Uso de geotecnologias na locação espacial de torres para detecção de incêndios florestais no semiárido nordestino. **Revista Floresta**, Curitiba, v. 44, n. 1, p. 133-142, 2014.

BAHADORI, N.; RAZAVI-TERMEH, S. V.; SADEGHI-NIARAKI, A.; AL-KINDI, K. M.; ABUHMED, T.; NAZERI, B.; CHOI, S.-M. Wildfire Susceptibility Mapping Using Deep Learning Algorithms in Two Satellite Imagery Dataset. **Forests**, [s. l.], v. 14, n. 7, p. 1325, 2023. DOI: <https://doi.org/10.3390/f14071325>.

BARBOSA, A. H. da S.; CARVALHO, R. G. de; CAMACHO, R. G. V. Aplicação do NDVI para a análise da distribuição espacial da cobertura vegetal na região serrana de Martins e Portalegre - Estado do Rio Grande do Norte. **Revista do Departamento de Geografia**, [s. l.], v. 33, p. 128, 2017.

BENALI, A.; APARÍCIO, B. A.; GONÇALVES, A.; OLIVEIRA, S. Defining priorities for wildfire mitigation actions at the local scale: insights from a novel risk analysis method applied in Portugal. **Frontiers in Forests and Global Change**, [s. l.], v. 6, p. 1-16, 2023. DOI: <https://doi.org/10.3389/ffgc.2023.1270210>.

BENDICK, R.; HOYLMAN, Z. H. Topological data analysis reveals parameters with prognostic skill for extreme wildfire size. **Environmental Research Letters**, [s. l.], v. 15, n. 10, p. 104039, 2020. DOI: <https://doi.org/10.1088/1748-9326/aba8c2>.

BRASIL. Ministério de Minas e Energia. Serviço Geológico do Brasil - CPRM. **Mapa geológico do estado do Piauí**. 2. ed. Teresina: CPRM, 2006.

CÂMARA, G.; PALOMO, D.; SOUZA, R. C. M. de; OLIVEIRA, O. R. F. de. Towards a generalized map algebra: principles and data types. In: SIMPÓSIO BRASILEIRO DE GEOINFORMÁTICA, 7., 2005, Campos do Jordão. **Anais [...]**. São José dos Campos: INPE, 2005. p. 66-81.

CAMARGO, L. S.; SILVA, R. W.; AMARAL, S. S.; SILVA, A. P.; FERRELI, T.; SILVA, M. P. D. Mapeamento de áreas susceptíveis a incêndios florestais do município de Petrópolis-RJ. **Anuário do Instituto de Geociências - UFRJ**, [s. l.], v. 42, n. 1, p. 630-641, 2019. DOI: https://doi.org/10.11137/2019_1_630_641.

CANADELL, J. G. et al. Multi-decadal increase of forest burned area in Australia is linked to climate change. **Nature Communications**, [s. l.], v. 12, n. 1, 2021.

CARVALHO, J. R. M.; CURI, W. F.; CURI, R. C.; CARVALHO, E. K. M. A. Metodologia para avaliar a sustentabilidade ambiental de municípios utilizando análise multicritério. **Revista REUNIR: Revista de Administração, Contabilidade e Sustentabilidade**, [s. l.], v. 1, n. 1, p. 18-34, 2011.

CHAN, K. K. L.; TOMLIN, C. D. Map Algebra as a Spatial Language. **Cognitive and Linguistic Aspects of Geographic Space**, [s. l.], p. 351-360, 1991. DOI: https://doi.org/10.1007/978-94-011-2606-9_19.

CHICAS, S. D.; NIELSEN, J. Ø. Who are the actors and what are the factors that are used in models to map forest fire susceptibility? A systematic review. **Natural Hazards**, [s. l.], v. 114, n. 3, p. 2417-2434, 2022. DOI: <https://doi.org/10.1007/s11069-022-05495-5>.

COSTA, H. G. **Introdução ao método de análise hierárquica: análise multicritério no auxílio à decisão**. Niterói: [s. n.], 2002. 104 p.

SILVA FIGUEREDO, E. da; SILVA, A. J. da; MOURA, J. T. V. de. Análise da estrutura fundiária na bacia hidrográfica do rio Uruçuí-Preto, Piauí. **Research, Society and Development**, [s. l.], v. 12, n. 5, p. e14012541601, 2023.

MEDEIROS, R. M. de; HOLANDA, R. M. de; FRANÇA, M. V. de. Interpolação da insolação média para o estado do Piauí-Brasil. **Revista de Geografia**, Recife, v. 35, n. 5, 2018.

DOMICIANO, S. M. R. **Classificação de perigo de incêndios na bacia hidrográfica do Médio Paraíba do Sul: combinação da metodologia AHP e o SIG**. 2024. 92 f. Dissertação (Mestrado Profissional em Rede Nacional em Gestão e Regulação de Recursos Hídricos - PROF-ÁGUA) - Centro de Tecnologia e Ciências, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2024.

SANTOS LOBATO, F. dos; GOMES, T. C.; PALHARES, J. M. NDVI aplicado à análise da dinâmica temporal da cobertura vegetal da terra da bacia do rio Pedreira-Amapá, Brasil. **Revista Ciência Geográfica**, [s. l.], v. 29, n. 2, 2025.

DUARTE, M. L. **Previsão da suscetibilidade a incêndios e queimadas utilizando um modelo baseado em inteligência artificial e sistema de inferência fuzzy**. 2022. Tese (Doutorado em Ciências Ambientais) - Universidade Estadual Paulista, Sorocaba, 2022.

ESLAMI, R.; AZARNOUSH, M.; KIALASHKI, A.; KAZEMZADEH, F. GIS-based forest fire susceptibility assessment by random forest, artificial neural network and logistic regression methods. **Journal of Tropical Forest Science**, [s. l.], v. 33, n. 2, p. 173-184, 2021. DOI: <https://doi.org/10.26525/jtfs2021.33.2.173>.

ESTES, B. L. et al. Factors influencing fire severity under moderate burning conditions in the Klamath Mountains, northern California, USA. **Ecosphere**, [s. l.], v. 8, n. 5, p. e01794, 2017.

ESTEVAM, T. da S. **Análise da suscetibilidade a incêndios florestais no Parque Estadual do Itacolomi como ferramenta auxiliar de prevenção e combate às queimadas**. 2020. 63 f. Monografia (Graduação em Engenharia Ambiental) - Escola de Minas, Universidade Federal de Ouro Preto, Ouro Preto, 2020. Disponível em: <http://www.monografias.ufop.br/handle/35400000/2916>. Acesso em: 17 ago. 2024.

ESTÉVEZ, J.; SALINERO-DELGADO, M.; BERGER, K.; PIPIA, L.; RIVERA-CAICEDO, J. P.; WOCHER, M.; REYES-MUÑOZ, P.; TAGLIABUE, G.; BOSCHETTI, M.; VERRELST, J. Gaussian processes retrieval of crop traits in Google Earth Engine based on Sentinel-2 top-of-atmosphere data. **Remote Sensing of Environment**, [s. l.], v. 273, p. 112958, 2022. DOI: <https://doi.org/10.1016/j.rse.2022.112958>.

FEIZIZADEH, B.; BLASCHKE, T. GIS-multicriteria decision analysis for landslide susceptibility mapping: comparing three methods for the Urmia Lake basin, Iran. **Natural Hazards**, [s. l.], v. 65, n. 3, p. 2105-2128, 2012.

FREIRE, P. F. B. **Refletindo sobre o conceito do risco natural e de sua dimensão: breve análise dos incêndios florestais no Parque Nacional da Chapada dos Guimarães**. 2006. Tese (Doutorado) - Universidade Federal de Santa Catarina, Florianópolis, 2006.

FU, Y.; LI, R.; WANG, X.; BERGERON, Y.; VALERIA, O.; CHAVARDÈS, R. D.; WANG, Y.; HU, J. Fire Detection and Fire Radiative Power in Forests and Low-Biomass Lands in Northeast Asia: MODIS versus VIIRS fire products. **Remote Sensing**, [s. l.], v. 12, n. 18, p. 2870, 2020. DOI: <https://doi.org/10.3390/rs12182870>.

GAMEIRO, S. et al. Avaliação da cobertura vegetal por meio de índices de vegetação (NDVI, SAVI e IAF) na Sub-Bacia Hidrográfica do Baixo Jaguaribe, CE. **Terræ**, [s. l.], v. 13, n. 1-2, p. 15-22, 2016.

GHORBANZADEH, O.; BLASCHKE, T.; GHOLAMNIA, K.; ARYAL, J. Forest Fire Susceptibility and Risk Mapping Using Social/Infrastructural Vulnerability and Environmental Variables. **Fire**, [s. l.], v. 2, n. 3, p. 50, 2019. DOI: <https://doi.org/10.3390/fire2030050>.

GOEPEL, K. D. Implementation of an Online Software Tool for the Analytic Hierarchy Process (AHP-OS). **International Journal of the Analytic Hierarchy Process**, [s. l.], v. 10, n. 3, p. 469-487, 2018. DOI: <https://doi.org/10.13033/ijahp.v10i3.590>.

GOOGLE EARTH ENGINE. **Introdução ao Google Earth Engine**. Disponível em: <https://developers.google.com/earth-engine/guides?hl=pt-br/>. Acesso em: 9 set. 2025.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, [s. l.], v. 202, p. 18-27, 2017. DOI: <https://doi.org/10.1016/j.rse.2017.06.031>.

GOULART, A. A.; MORELLI, F.; SETZER, A.; FRANÇA, S. Focos de queimadas e incêndios detectados por satélites nas unidades de conservação do Cerrado no Mato Grosso em 2010. In: SIMPÓSIO BRASILEIRO DE GEOGRAFIA FÍSICA APLICADA, 14., 2011. **Anais [...]**. [S. l.: s. n.], 2011.

GUERRA, J. B.; SCHULTZ, B.; SANCHES, I. D. Mapeamento automático da expansão da agricultura anual no Matopiba entre 2002 e 2015 utilizando a plataforma Google Earth Engine. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2017, Santos. **Anais [...]**. São José dos Campos: INPE, 2017. p. 6850-6857.

GÜNGÖROĞLU, C.; İSMAİLOĞLU, İ.; KAPUKAYA, B.; ÖZCAN, O.; YANALAK, M.; MUSAOĞLU, N. Comparison between Post-Fire Analysis and Pre-Fire Risk Assessment According to Various Geospatial Data. **Sustainability**, [s. l.], v. 16, n. 4, p. 1569, 2024. DOI: <https://doi.org/10.3390/su16041569>.

HAMURCU, M.; EREN, T. Electric Bus Selection with Multicriteria Decision Analysis for Green Transportation. **Sustainability**, [s. l.], v. 12, n. 7, p. 2777, 2020. DOI: <https://doi.org/10.3390/su12072777>.

HE, Z.; FAN, G.; LI, Z.; LI, S.; GAO, L.; LI, X.; ZENG, Z.-C. Deep learning modeling of human activity affected wildfire risk by incorporating structural features: a case study in eastern China. **Ecological Indicators**, [s. l.], v. 160, p. 111946, 2024. DOI: <https://doi.org/10.1016/j.ecolind.2024.111946>.

HILL, M. J.; BRAATEN, R. O.; VEITCH, S. M. et al. Multi-criteria decision analysis in spatial decision support: the ASSESS analytic hierarchy process and the role of quantitative methods and spatially explicit analysis. **Environmental Modelling & Software**, [s. l.], v. 20, n. 7, p. 955-976, 2005.

HOLDEN, Z. A.; SWANSON, A.; LUCE, C. H.; JOLLY, W. M.; MANETA, M.; OYLER, J. W.; WARREN, D. A.; PARSONS, R.; AFFLECK, D. Decreasing fire season precipitation increased recent western US forest wildfire activity. **Proceedings of the National Academy of Sciences**, [s. l.], v. 115, n. 36, p. 8349-8357, 2018. DOI: <https://doi.org/10.1073/pnas.1802316115>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo brasileiro de 2022**. Rio de Janeiro: IBGE, 2022.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Programa Queimadas**. Disponível em: https://terrabrasilis.dpi.inpe.br/queimadas/situacao-atual/situacao_atual/. Acesso em: 19 ago. 2025.

JAISWAL, R. K.; MUKHERJEE, S.; RAJU, K. D.; SAXENA, R. Forest fire risk zone mapping from satellite imagery and GIS. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 4, n. 1, p. 1-10, 2002. DOI: [https://doi.org/10.1016/s0303-2434\(02\)00006-5](https://doi.org/10.1016/s0303-2434(02)00006-5).

JIMÉNEZ-RUANO, A.; MIMBRERO, M. R.; JOLLY, W. M.; FERNÁNDEZ, J. de la R. The role of short-term weather conditions in temporal dynamics of fire regime features in mainland Spain. **Journal of Environmental Management**, [s. l.], v. 241, p. 575-586, 2019. DOI: <https://doi.org/10.1016/j.jenvman.2018.09.107>.

JODHANI, K. H.; PATEL, H.; SONI, U.; PATEL, R.; VALODARA, B.; GUPTA, N.; PATEL, A.; OMAR, P. J. Assessment of forest fire severity and land surface

temperature using Google Earth Engine: a case study of Gujarat state, India. **Fire Ecology**, [s. l.], v. 20, n. 1, p. 1-21, 2024. DOI: <https://doi.org/10.1186/s42408-024-00254-2>.

JONES, M. W. et al. Global and regional trends and drivers of fire under climate change. **Reviews of Geophysics**, [s. l.], v. 60, n. 3, 2022.

JU, W.; XING, Z.; WU, J.; KANG, Q. Evaluation of forest fire risk based on multicriteria decision analysis techniques for Changzhou, China. **International Journal of Disaster Risk Reduction**, [s. l.], v. 98, p. 104082, 2023. DOI: <https://doi.org/10.1016/j.ijdrr.2023.104082>.

KALANTAR, B.; UEDA, N.; IDREES, M. O.; JANIZADEH, S.; AHMADI, K.; SHABANI, F. Forest Fire Susceptibility Prediction Based on Machine Learning Models with Resampling Algorithms on **Remote Sensing** Data. *Remote Sensing*, [s. l.], v. 12, n. 22, p. 3682, 2020. DOI: <https://doi.org/10.3390/rs12223682>.

KANE, V. R. et al. Water balance and topography predict fire and forest structure patterns. **Forest Ecology and Management**, [s. l.], v. 338, p. 1-13, 2015. DOI: <https://doi.org/10.1016/j.foreco.2014.10.038>.

KOLANEK, A.; SZYMANOWSKI, M.; RACZYK, A. Human Activity Affects Forest Fires: the impact of anthropogenic factors on the density of forest fires in Poland. **Forests**, [s. l.], v. 12, n. 6, p. 728, 2021. DOI: <https://doi.org/10.3390/f12060728>.

LADISLAU, F. F.; SILVA, J. C.; MOREIRA, A. P. M.; NASCIMENTO, G. L.; RUCHKYS, U. A. Análise multicritério aplicada ao mapeamento de risco de incêndio na APA Sul-RMBH. **Caderno de Geografia**, [s. l.], v. 31, n. 66, p. 667-681, 2021.

LIMA, I. C. **Monitoramento dos focos de queimadas nos biomas Amazônia e Cerrado nas estações seca e chuvosa de 2017**. 2018. 37 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) - Universidade Federal de Uberlândia, Uberlândia, 2018.

LIU, J.; HAGAN, D. F. T.; HOLMES, T. R.; LIU, Y. An Analysis of Spatio-Temporal Relationship between Satellite-Based Land Surface Temperature and Station-Based Near-Surface Air Temperature over Brazil. **Remote Sensing**, [s. l.], v. 14, n. 17, p. 4420, 2022. DOI: <https://doi.org/10.3390/rs14174420>.

LUKE, R. H.; MCARTHUR, A. G. **Bushfires in Australia**. Canberra: Australian Government Publishing Service, 1978. 359 p.

LUZ, L. B. et al. Utilização do NDVI e NDBI para avaliação da expansão urbana no município do Rio das Ostras-RJ, utilizando a plataforma Google Earth Engine. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos. **Anais [...]**. São José dos Campos: INPE, 2019. p. 3493-3495. Disponível em: <https://proceedings.science/sbsr-2019/trabalhos/utilizacao-do-ndvi-e-ndbi-para-avaliacao-da-expansao-urbana-no-municipio-do-rio?lang=pt-br>. Acesso em: 28 ago. 2025.

LYU, X.; CHEN, H.; TIAN, Y.; ZHENG, C.; CHEN, G. **Remote Sensing** Recognition Framework for Straw Burning Integrating Spatio-Temporal Weights and Semi-Supervised Learning. *Remote Sensing*, [s. l.], v. 18, n. 6, p. 903, 2026. DOI: <https://doi.org/10.3390/rs18060903>.

MA, Q.; BALES, R. C.; RUNGEE, J.; CONKLIN, M. H.; COLLINS, B. M.; GOULDEN, M. L. Wildfire controls on evapotranspiration in California's Sierra Nevada. **Journal of Hydrology**, [s. l.], v. 590, p. 125364, 2020. DOI: <https://doi.org/10.1016/j.jhydrol.2020.125364>.

MANKIN, K. R.; PATEL, R. Wildfire Burn Severity Affects Postfire Shifts in Evapotranspiration in Subalpine Forests. **Journal of Natural Resources and Agricultural Ecosystems**, [s. l.], v. 1, n. 1, p. 1-11, 2023. DOI: <https://doi.org/10.13031/jnrae.15438>.

MAPBIOMAS FOGO. **RAF 2024: relatório anual do fogo no Brasil: coleção 4 de mapas de áreas queimadas do MapBiomas Fogo (1985 a 2024)**. MapBiomas, [s. l.], v. 1, 2025. DOI: <https://doi.org/10.58053/MapBiomas/JKWSW7>.

MAPBIOMAS. **Projeto MapBiomas: mapeamento das áreas queimadas no Brasil entre 1985 a 2023: coleção 3**. 2024. Disponível em: https://brasil.mapbiomas.org/wp-content/uploads/sites/4/2024/06/Fact_Fogo_colecao3_18.06-OK-10h11.pdf. Acesso em: 12 jul. 2024.

MARTINS, R. A. **Análise da correlação entre variáveis climáticas e área queimada utilizando Google Earth Engine para o estado de Rondônia**. 2024. 50 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental e Sanitária) - Campus Ji-Paraná, Fundação Universidade Federal de Rondônia, Ji-Paraná, 2024.

MATEUS, M. G.; MOTA, F. P.; AGUIAR, M. S.; ADAMATTI, D. F. Visualizador de Água e Solo: uma aplicação voltada para o gerenciamento de recursos naturais desenvolvida na plataforma Google Earth Engine. In: WORKSHOP DE COMPUTAÇÃO APLICADA À GESTÃO DO MEIO AMBIENTE E RECURSOS NATURAIS (WCAMA), 12., 2021, Evento Online. **Anais [...]**. Porto Alegre: Sociedade Brasileira de Computação, 2021. p. 157-166. DOI: <https://doi.org/10.5753/wcama.2021.15747>.

MEDEIROS, R. M.; TAVARES, A. L.; GOMES FILHO, M. F. Climatologia da precipitação na bacia hidrográfica do rio Uruçuí Preto-PI, Brasil. In: CONGRESSO TÉCNICO CIENTÍFICO DA ENGENHARIA E DA AGRONOMIA, 2015, Fortaleza. **Anais [...]**. Fortaleza: [s. n.], 2015.

MOURÃO, D. da S. **Análise espacial multicritério na avaliação do risco sísmico: caso de estudo da região do Algarve, Portugal**. 2021. Dissertação (Mestrado em Sistemas de Informação Geográfica - Tecnologias e Aplicações) - Universidade de Lisboa, Faculdade de Ciências, Lisboa, 2021.

NEVES, S. M.; BARBOSA, A. M. F.; MELO E SOUSA, R. Análise geoambiental do município de Uruçuí-PI. **Revista de Geografia UFPE**, Recife, v. 32, n. 1, p. 151-166, 2015.

NIKOLIĆ, G.; VUJOVIĆ, F.; GOLIJANIN, J.; ŽILJEG, A.; VALJAREVIĆ, A. Modelling of Wildfire Susceptibility in Different Climate Zones in Montenegro Using GIS-MCDA. **Atmosphere**, [s. l.], v. 14, n. 6, p. 929, 2023. DOI: <https://doi.org/10.3390/atmos14060929>.

OLIVEIRA-JÚNIOR, J. F. de; SHAH, M.; ABBAS, A.; CORREIA FILHO, W. L. F.; SILVA JUNIOR, C. A. da; SANTIAGO, D. de B.; TEODORO, P. E.; MENDES, D.; SOUZA, A. de; AVIV-SHARON, E. Spatiotemporal Analysis of Fire Foci and Environmental Degradation in the Biomes of Northeastern Brazil. **Sustainability**, [s. l.], v. 14, n. 11, p. 6935, 2022. DOI: <https://doi.org/10.3390/su14116935>.

OTSUKI, R. G. **Estimativa de séries anuais de evapotranspiração real e vazão em bacias sem monitoramento fluviométrico com base nas hipóteses de Budyko**. 2015. 111 f. Dissertação (Mestrado em Tecnologia Ambiental e Recursos Hídricos) - Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, 2015.

ÖZCAN, Z.; CAGLAYAN, İ.; KABAK, Ö.; GÜL, F. K. Integrated risk mapping for forest fire management using the analytical hierarchy process and ordered weighted average: a case study in southern Turkey. **Natural Hazards**, [s. l.], v. 121, n. 1, p. 959-1001, 2024. DOI: <https://doi.org/10.1007/s11069-024-06810-y>.

PALUDO, A. **Google Earth Engine para mapeamento de culturas agrícolas no Paraná**. 2019. 75 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel, 2019.

PARREIRAS, R. O. **Algoritmos evolucionários e técnicas de tomada de decisão em análise multicritério**. 2006. Tese (Doutorado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, 2006.

PEIXOTO, R. de A. O.; FERNANDES, J. C.; SCHMIDT, M. A. R.; PEREIRA, C. E. Análise multicritério com uso da AHP para avaliação temporal na vulnerabilidade ambiental: estudo de caso na bacia hidrográfica do Uberabinha, MG. **Revista Gestão & Sustentabilidade Ambiental**, [s. l.], v. 8, n. 3, p. 141-158, 2019. DOI: <https://doi.org/10.19177/rgsa.v8e32019141-158>.

PEREIRA, A.; GAMA, V. Anthropization on the Cerrado biome in the Brazilian Uruçuí-Una Ecological Station estimated from orbital images. **Brazilian Journal of Biology**, [s. l.], v. 70, n. 4, p. 969-976, 2010. DOI: <https://doi.org/10.1590/S1519-69842010000500008>.

PIAO, Y.; LEE, D.; PARK, S.; KIM, H. G.; JIN, Y. Forest fire susceptibility assessment using Google Earth Engine in Gangwon-do, Republic of Korea. **Geomatics, Natural Hazards and Risk**, [s. l.], v. 13, n. 1, p. 432-450, 2022. DOI: <https://doi.org/10.1080/19475705.2022.2030808>.

PIRALILOU, S. T.; EINALI, G.; GHORBANZADEH, O.; NACHAPPA, T. G.; GHOLAMNIA, K.; BLASCHKE, T.; GHAMISI, P. A Google Earth Engine Approach for Wildfire Susceptibility Prediction Fusion with **Remote Sensing** Data of Different Spatial Resolutions. *Remote Sensing*, [s. l.], v. 14, n. 3, p. 672, 2022. DOI: <https://doi.org/10.3390/rs14030672>.

PIVELLO, V. R.; VIEIRA, I.; CHRISTIANINI, A. V.; RIBEIRO, D. B.; MENEZES, L. da S.; BERLINCK, C. N.; MELO, F. P. L.; MARENGO, J. A.; TORNQUIST, C. G.; TOMAS, W. M. Understanding Brazil's catastrophic fires: causes, consequences and policy needed to prevent future tragedies. **Perspectives in Ecology and Conservation**, [s. l.], v. 19, n. 3, p. 233-255, 2021. DOI: <https://doi.org/10.1016/j.pecon.2021.06.005>.

POON, P. K.; KINOSHITA, A. M.; SILVA, J. A. da; PONCE, V. M. Evapotranspiração pós-incêndios florestais em regiões semiáridas. In: CONGRESO LATINOAMERICANO DE HIDRÁULICA, 28., 2018, Buenos Aires. **Anais [...]**. Buenos Aires: [s. n.], 2018.

PYNE, S. J. Megaburning: the meaning of megafires and the means of the management. In: INTERNATIONAL WILDLAND FIRE CONFERENCE, 4., 2007, Seville. **Proceedings [...]**. Seville: [s. n.], 2007.

QUINTANO, C.; FERNÁNDEZ-MANSO, A.; FERNÁNDEZ-GUISURAGA, J. M.; ROBERTS, D. A. Improving Fire Severity Analysis in Mediterranean Environments: a comparative study of eeMETRIC and SSEBop Landsat-based evapotranspiration models. **Remote Sensing**, [s. l.], v. 16, n. 2, p. 361, 2024. DOI: <https://doi.org/10.3390/rs16020361>.

RIHAN, M.; BINDAJAM, A. A.; TALUKDAR, S.; SHAHFAHAD; NAIKOO, M. W.; MALLICK, J.; RAHMAN, A. Forest fire susceptibility mapping with sensitivity and uncertainty analysis using machine learning and deep learning algorithms. **Advances in Space Research**, [s. l.], v. 72, n. 2, p. 426-443, 2023. DOI: <https://doi.org/10.1016/j.asr.2023.03.026>.

ROCHA, J. V. V.; VIEIRA, V. de C. B.; SILVA, A. J. da. Análise espaço-temporal da expansão do cultivo da soja em Uruçuí-Piauí. **Research, Society and Development**, [s. l.], v. 11, n. 6, p. e37411629174, 2022.

ROCHA, M. I. S.; NASCIMENTO, D. T. F. Distribuição espaço-temporal das queimadas no bioma Cerrado (1999/2018) e sua ocorrência conforme os diferentes tipos de cobertura e uso do solo. **Revista Brasileira de Geografia Física**, [s. l.], v. 14, n. 3, p. 1220-1235, 2021. DOI: 10.26848/rbgf.v14.3.p1220-1235. Disponível em: <https://periodicos.ufpe.br/revistas/index.php/rbgf/article/view/244925>. Acesso em: 10 jul. 2024.

RODRIGUES, A. A.; MACEDO, M. N.; SILVÉRIO, D. V.; MARACAHIPES, L.; COE, M. T.; BRANDO, P. M.; SHIMBO, J. Z.; RAJÃO, R.; SOARES-FILHO, B.; BUSTAMANTE, M. M. C. Cerrado deforestation threatens regional climate and water

availability for agriculture and ecosystems. **Global Change Biology**, [s. l.], v. 28, n. 22, p. 6807-6822, 2022. DOI: <https://doi.org/10.1111/gcb.16386>.

SAATY, T. L. How to make a decision: the Analytic Hierarchy Process. **European Journal of Operational Research**, [s. l.], v. 48, n. 1, p. 9-26, 1990.

SÁNCHEZ, M. B.; TONINI, M.; MAPELLI, A.; FIORUCCI, P. Spatial Assessment of Wildfires Susceptibility in Santa Cruz (Bolivia) Using Random Forest. **Geosciences**, [s. l.], v. 11, n. 5, p. 224, 2021. DOI: <https://doi.org/10.3390/geosciences11050224>.

SANTOS, N. B. F. dos; FERREIRA JÚNIOR, L. G.; FERREIRA, N. C. Distribuição espacial da temperatura de superfície no bioma Cerrado: uma análise a partir de dados orbitais de resolução moderada, para o período de 2003 a 2008. **Ciência e Cultura**, [s. l.], v. 63, n. 3, p. 30-33, 2011.

SCHNEIDER, R. G.; BREEDLOVE, D. **Fire Management Study Unit**. [S. l.: s. n.], [s. d.]. 38 p. Disponível em: https://www.fs.usda.gov/Internet/FSE_DOCUMENTS/fsm9_028958.pdf. Acesso em: 16 ago. 2024.

SCHROEDER, A. K. **Avaliação de tecnologias normatizadas e wetlands construídos empregados no tratamento descentralizado de esgoto por meio de análise multicriterial**. 2020. 139 f. Dissertação (Mestrado em Engenharia Ambiental) - Programa de Pós-Graduação em Engenharia Ambiental, Universidade Federal de Santa Catarina, Florianópolis, 2020.

SILVA JUNIOR, C. H. L.; PESSÔA, A. C. M.; CARVALHO, N. S.; REIS, J. B. C.; ANDERSON, L. O.; ARAGÃO, L. E. O. C. The Brazilian Amazon deforestation rate in 2020 is the greatest of the decade. **Nature Ecology & Evolution**, [s. l.], v. 5, n. 2, p. 144-145, 2020. DOI: <https://doi.org/10.1038/s41559-020-01368-x>.

SILVA JÚNIOR, J. G. da et al. **Avaliação de perigo de incêndios florestais para o Parque Nacional de Chapada dos Guimarães utilizando Google Earth Engine**. 2023. Tese (Doutorado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2023.

SILVA, C. M. A. da; IWATA, B. de F. Análise do comportamento de queimadas no estado do Piauí e ocorrência de doenças respiratórias no cenário pandêmico. **ClimaCom**, Campinas, ano 7, n. 19, 2020. Disponível em: <https://climacom.mudancasclimaticas.net.br/queimadas-piaui-2/>. Acesso em: 16 ago. 2025.

SILVA, R. M. da; LOPES, A. G.; SANTOS, C. A. G. Deforestation and fires in the Brazilian Amazon from 2001 to 2020: impacts on rainfall variability and land surface temperature. **Journal of Environmental Management**, [s. l.], v. 326, p. 116664, 2023. DOI: <https://doi.org/10.1016/j.jenvman.2022.116664>.

SIVRIKAYA, F.; KÜÇÜK, Ö. Modeling forest fire risk based on GIS-based analytical hierarchy process and statistical analysis in Mediterranean region. **Ecological Informatics**, [s. l.], v. 68, p. 101537, 2022. DOI: <https://doi.org/10.1016/j.ecoinf.2021.101537>.

SOARES, R. V. **Prevenção e controle de incêndios florestais**. Curitiba: FUPEF, 1984. 160 p.

SOARES, R. V. **Incêndios florestais: controle e uso do fogo**. Curitiba: Fundação de Pesquisa Florestal do Paraná, 1985. 213 p.

SOARES, R. V.; BATISTA, A. C. **Incêndios florestais: controle, efeitos e uso do fogo**. Curitiba: UFPR, 2007. 264 p.

SOKOLIK, I. N. et al. Progress and challenges in quantifying wildfire smoke emissions, their properties, transport, and atmospheric impacts. **Journal of Geophysical Research: Atmospheres**, [s. l.], v. 124, n. 23, p. 13005-13025, 2019. DOI: <https://doi.org/10.1126/sciadv.aav7336>.

SOUZA, D. S. L. de; DELLARGINE, F. L.; MIRA, Í. R. C. de; SILVA, G. T.; SILVA, M. L. da. Análise e mapeamento da fragilidade ambiental no município de Inconfidentes-MG. **Revista Brasileira de Geografia Física**, [s. l.], v. 13, n. 5, p. 2269-2292, 2020.

SOUZA, J. P. S.; OLIVEIRA, G. S. de; CARDOZO, É. P.; ALVES, A. M. O. S.; COSTA, A. A. A.; ANDRADE, P. C. de R. Spatial Modeling of Forest Fire Risks in a Watershed Using Remote Sensing. **Revista de Gestão Social e Ambiental**, [s. l.], v. 19, n. 1, p. 1-14, 2025. DOI: <https://doi.org/10.24857/rgsa.v19n1-033>.

SOUZA, N. G. A. **Mapeamento de risco de incêndios florestais em parques, a partir de análise multicritério**. 2022. 70 f. Dissertação (Mestrado em Qualidade Ambiental) - Universidade Federal de Uberlândia, Uberlândia, 2022. DOI: <http://doi.org/10.14393/ufu.di.2022.5373>.

SOUZA, R. dos P. **Dinâmica do fogo e mudanças de uso e cobertura do solo na Mata Atlântica fluminense: análise multitemporal com o Google Earth Engine (1985-2023)**. 2025. 33 f. Monografia (Bacharelado em Engenharia Florestal) - Instituto de Florestas, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2025.

TAMIMINIA, H.; SALEHI, B.; MAHDIANPARI, M.; QUACKENBUSH, L.; ADELI, S.; BRISCO, B. Google Earth Engine for geo-big data applications: a meta-analysis and systematic review. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s. l.], v. 164, p. 152-170, 2020. DOI: <https://doi.org/10.1016/j.isprsjprs.2020.04.001>.

TEDIM, F.; CARVALHO, S. Vulnerabilidade aos incêndios florestais: reflexões em torno de aspectos conceituais e metodológicos. **Territorium**, [s. l.], n. 20, p. 85-99, 2013.

TOMLIN, C. D. Map algebra: one perspective. **Landscape and Urban Planning**, [s. l.], v. 30, n. 1-2, p. 3-12, 1994. DOI: [https://doi.org/10.1016/0169-2046\(94\)90063-9](https://doi.org/10.1016/0169-2046(94)90063-9).

TORRES, F. T. P. et al. Análise do perfil dos incêndios florestais no Parque Estadual da Serra do Brigadeiro e entorno (MG). **Ciência Florestal**, [s. l.], v. 28, n. 3, p. 1008-

1021, 2018. DOI: 10.5902/1980509833384. Disponível em: <https://periodicos.ufsm.br/cienciaflorestal/article/view/33384>. Acesso em: 17 ago. 2024.

TZENG, G.; HUANG, J. **Multiple Attribute Decision Making: methods and applications**. Boca Raton: CRC Press, 2011. 335 p.

URUÇUÍ (Município). **Conheça Uruçuí-PI**. Uruçuí: Prefeitura Municipal, 2021. Disponível em: <https://urucui.pi.gov.br/nossa-historia>. Acesso em: 27 ago. 2025.

VAREJÃO-SILVA, M. A. **Meteorologia e climatologia**. Versão Digital 2. Recife: [s. n.], 2006. 449 p. Disponível em: https://icat.ufal.br/laboratorio/clima/data/uploads/pdf/METEOROLOGIA_E_CLIMATOLOGIA_VD2_Mar_2006.pdf. Acesso em: 23 set. 2025.

VIEIRA, G. dos S. **Análise espaço-temporal do fogo no bioma Caatinga**. 2021. 42 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Florestal) - Universidade de Brasília, Brasília, 2021.

VILLAVICENCIO, L. M. M.; MENDES, D.; ANDRADE, L. M. B.; MONTEIRO, F. F. Google Earth Engine: Mapping Changes in the Vilcanota-Peru Mountain Range. **Anuário do Instituto de Geociências - UFRJ**, [s. l.], v. 41, p. 427-433, 2018. Disponível em: http://www.anuario.igeo.ufrj.br/2018_03/2018_3_427-433.pdf. Acesso em: 28 ago. 2020. DOI: https://doi.org/10.11137/2018_3_427_433.

WANG, Z.; HE, B.; CHEN, R.; FAN, C. Improving Wildfire Danger Assessment Using Time Series Features of Weather and Fuel in the Great Xing'an Mountain Region, China. **Forests**, [s. l.], v. 14, n. 5, p. 986, 2023. DOI: <https://doi.org/10.3390/f14050986>.

WEISS, R.; PIPPI, L. G. A. Análise multicritério na definição de vulnerabilidade ambiental. **Terr@ Plural**, [s. l.], v. 13, n. 3, p. 272-295, 2019. Disponível em: <https://revistas.uepg.br/index.php/tp/article/view/13438>. Acesso em: 9 dez. 2025.

WHITE, L. A. S.; WHITE, B. L. A.; RIBEIRO, G. T. Modelagem espacial de risco de incêndio florestal para o município de Inhambupe, Bahia, Brasil. **Pesquisa Florestal Brasileira**, [s. l.], v. 36, n. 85, p. 41-49, 2021. DOI: 10.4336/2016.pfb.36.85.850. Disponível em: <https://pfb.sede.embrapa.br/pfb/article/view/850>. Acesso em: 28 maio 2025.

ZOMER, R. J.; XU, J.; TRABUCCO, A. Version 3 of the Global Aridity Index and Potential Evapotranspiration Database. **Scientific Data**, [s. l.], v. 9, n. 1, p. 1-15, 2022. DOI: <https://doi.org/10.1038/s41597-022-01493-1>.

APÊNDICE A – CÓDIGO GEE DE IDENTIFICAÇÃO ÁREAS DE RISCO DE INCÊNDIOS FLORESTAIS NO MUNICÍPIO DE URUCUI

Link de acesso direto no GEE:

<https://code.earthengine.google.com/7a595e4f183d5e925ebfaaba1b5517e9>

Link de acesso em ambiente GitHub: <https://github.com/eng-luiz-eduardo/Script-de-risco-a-incendios-florestais-urucui>

```
// =====
// MAPA DE RISCO DE INCENDIOS FLORESTAIS - URUCUI (PI)
// Produto apresentado como parte integrante dos requisitos
// para a obtencao do título de Mestre em Analise e Planejamento
// Espacial pelo programa de Pos-Graduação em Análise e
// Planejamento Espacial (MAPEPROF) do IFPI
//
// Discente: Luiz Eduardo Araujo Silva
// Orientadora: Dra. Sammya Vanessa Chaves Vieira
// Coorientador: Dr. Eduilson Livio Neves da Costa Carneiro
// =====
```

// VARIÁVEIS UTILIZADAS

```
// -----
// 1. Precipitação acumulada em 15 dias (CHIRPS)
// 2. Temperatura de superfície (MODIS Terra + Aqua)
// 3. NDVI (Sentinel-2 SR Harmonized)
// 4. Declividade (SRTM)
// 5. Altitude (SRTM)
// 6. Orientação das encostas / aspecto (SRTM)
```

// LÓGICA GERAL

```
// -----
// - Cada variável é processada e padronizada para a escala 0–1.
```

```

// - As variáveis são integradas por álgebra de mapas.
// - Os pesos são definidos a partir do método AHP.
// - O resultado final é um índice contínuo de risco
// ("riscoIncendio"), convertido também para percentual.
// - Para facilitar a leitura cartográfica, o índice percentual
// é exibido em quatro classes temáticas:
// Q1 = risco baixo
// Q2 = risco moderado
// Q3 = risco alto
// Q4 = risco muito alto

//
// -----
// 1. CONFIGURAÇÃO INICIAL
// -----

// Define a área de interesse (AOI) a partir do limite municipal
// de Urucuí armazenado como FeatureCollection no GEE.
var urucui = ee.FeatureCollection('projects/ee-
mapeprof/assets/MAPBIOMAS/urucui');

// Cria o mapa principal da interface.
var mapa = ui.Map();

// Centraliza a visualização na área de estudo.
// O nível 8 foi adotado para permitir boa visualização do município.
mapa.centerObject(urucui, 8);

// Define o tipo de mapa-base como relevo/terrain.
mapa.setOptions('TERRAIN');

// Altera o cursor para melhorar a experiência da consulta pontual.

```

```
mapa.style().set('cursor', 'crosshair');
```

```
// Habilita alguns controles úteis ao usuário.
```

```
mapa.setControlVisibility({
  zoomControl: true,
  scaleControl: true,
  mapTypeControl: false,
  fullscreenControl: true,
  layerList: true
});
```

```
// -----
// 2. FUNÇÕES AUXILIARES
// -----
```

```
/**
 * minMaxNorm(img, bandName, scale)
 * -----
 * Função de normalização min-max.
 *
 * O que faz:
 * - Obtém o valor mínimo e máximo da banda dentro da área de estudo.
 * - Reescala a variável para o intervalo entre 0 e 1.
 *
 * Por que é usada:
 * - As variáveis do modelo possuem unidades diferentes
 *   (mm, °C, NDVI, metros, graus etc.).
 * - A normalização permite compará-las e combiná-las
 *   dentro da álgebra de mapas.
 *
 * Observação:
 * - O parâmetro "scale" é ajustado conforme a resolução
```

```

* mais coerente com cada variável.
*/
function minMaxNorm(img, bandName, scale) {
  var stats = img.reduceRegion({
    reducer: ee.Reducer.minMax(),
    geometry: urucui.geometry(),
    scale: scale,
    bestEffort: true,
    maxPixels: 1e13
  });

  var vmin = ee.Number(stats.get(bandName + '_min'));
  var vmax = ee.Number(stats.get(bandName + '_max'));

  // Evita divisão por zero caso a amplitude da variável seja muito pequena.
  var denom = vmax.subtract(vmin).max(1e-6);

  return {
    norm: img.subtract(vmin).divide(denom).clamp(0, 1),
    min: vmin,
    max: vmax,
    denom: denom
  };
}

/**
 * resumoVariavel(img, scale)
 * -----
 * Calcula estatísticas simples de conferência:
 * mínimo, máximo e média.
 *
 * Por que é usada:

```

```

* - Auxilia a auditoria do processamento.
* - Permite conferir rapidamente, no console,
* se a variável está dentro da faixa esperada.
*/

function resumoVariavel(img, scale) {
  return img.reduceRegion({
    reducer: ee.Reducer.min()
      .combine({reducer2: ee.Reducer.max(), sharedInputs: true})
      .combine({reducer2: ee.Reducer.mean(), sharedInputs: true}),
    geometry: urucui.geometry(),
    scale: scale,
    bestEffort: true,
    maxPixels: 1e13
  });
}

/**
 * fmt(n, decimals)
 * -----
 * Formata valores numéricos para exibição textual no painel.
 */

function fmt(n, decimals) {
  if (n === null || n === undefined) return 'sem dado';
  return Number(n).toFixed(decimals || 2);
}

/**
 * linhaLegenda(color, labelWidget)
 * -----
 * Cria uma linha da legenda temática no painel lateral:
 * uma caixa colorida + o texto explicativo.
 */

```



```
function linhaLegenda(color, labelWidget) {
    var box = ui.Label("", {
        backgroundColor: color,
        padding: '8px',
        margin: '0 8px 4px 0',
        border: '1px solid #d6d3d1'
    });

    return ui.Panel([box, labelWidget], ui.Panel.Layout.flow('horizontal'));
}
```

```
/**
 * separador()
 * -----
 * Cria uma linha visual de separação entre blocos do painel.
 */
function separador() {
    return ui.Panel({
        style: {
            height: '1px',
            backgroundColor: '#d8d2c8',
            margin: '12px 0'
        }
    });
}
```

```
// -----
// 3. PRECIPITAÇÃO - CHIRPS (ACUMULADO DE 15 DIAS)
// -----
```

```
// A coleção CHIRPS Daily foi escolhida por sua ampla utilização
```

```

// em estudos ambientais e por disponibilizar precipitação diária
// com cobertura contínua e adequada ao contexto regional.
var chirps = ee.ImageCollection('UCSB-CHG/CHIRPS/DAILY')
  .filterBounds(urucui);

// Seleciona a imagem mais recente disponível na coleção.
var ultimaImagemChuva = ee.Image(chirps.sort('system:time_start', false).first());
var ultimaDataChuva = ee.Date(ultimaImagemChuva.get('system:time_start'));

// Define a janela temporal de 15 dias.
// Essa escolha foi adotada para representar melhor a condição
// hídrica recente, evitando depender apenas da chuva de 24h.
var inicioChuva = ultimaDataChuva.advance(-14, 'day');
var fimChuva = ultimaDataChuva.advance(1, 'day');

// Soma a precipitação do período e recorta ao limite do município.
var acumulado15d = chirps
  .filterDate(inicioChuva, fimChuva)
  .sum()
  .clip(urucui)
  .rename('acumulado15d');

// A escala 5000 m foi adotada porque o CHIRPS possui resolução
// aproximada de 0,05 grau (~5 km).
var pStats = minMaxNorm(acumulado15d, 'acumulado15d', 5000);

// Inverte a lógica da precipitação.
// Menor precipitação acumulada = maior risco potencial.
var precipInv = ee.Image.constant(pStats.max)
  .subtract(acumulado15d)
  .rename('precipInv');

```

```

// Gera a camada final de risco da precipitação, já padronizada de 0 a 1.
var precipRisco = precipInv
  .divide(pStats.denom)
  .clamp(0, 1)
  .rename('precipRisco');

// -----
// 4. TEMPERATURA DE SUPERFÍCIE - MODIS TERRA + AQUA
// -----

// Seleciona os produtos MODIS Terra e Aqua.
// Foram usadas as bandas diurna e noturna de LST para reduzir
// o efeito de extremos e representar melhor a condição térmica.
var lstTerra = ee.ImageCollection('MODIS/061/MOD11A1')
  .filterBounds(urucui)
  .select(['LST_Day_1km', 'LST_Night_1km']);

var lstAqua = ee.ImageCollection('MODIS/061/MYD11A1')
  .filterBounds(urucui)
  .select(['LST_Day_1km', 'LST_Night_1km']);

// Une Terra e Aqua em uma única coleção para ampliar a cobertura.
var modLST = lstTerra.merge(lstAqua);

// Localiza a data mais recente disponível.
var ultimaImagemLST = ee.Image(modLST.sort('system:time_start', false).first());
var ultimaDataLST = ee.Date(ultimaImagemLST.get('system:time_start'));

/**
 * toCelsius(img)

```

* -----

* Converte LST do produto MODIS para graus Celsius.

*

* Observação:

* - Nos produtos MODIS, o fator de escala é 0.02.

* - A temperatura original está em Kelvin.

*/

```
function toCelsius(img) {
  var day = img.select('LST_Day_1km')
    .multiply(0.02)
    .subtract(273.15)
    .rename('LST_Day_C');

  var night = img.select('LST_Night_1km')
    .multiply(0.02)
    .subtract(273.15)
    .rename('LST_Night_C');

  return day.addBands(night)
    .copyProperties(img, ['system:time_start']);
}
```

```
var lstC = modLST.map(toCelsius);
```

```
// Janela principal de 7 dias.
```

```
// Essa janela representa a condição térmica mais recente.
```

```
var inicio7 = ultimaDataLST.advance(-6, 'day');
```

```
var fim7 = ultimaDataLST.advance(1, 'day');
```

```
var temp7 = lstC.filterDate(inicio7, fim7).mean().clip(urucui);
```

```
// Reduz as bandas diurna e noturna para uma média combinada.
```

```

var tempCombinada7 =
temp7.reduce(ee.Reducer.mean()).rename('tempCombinada');

// Janela complementar de 30 dias.
// Utilizada para preencher lacunas da janela principal,
// especialmente em situações de menor disponibilidade de pixels válidos.
var inicio30 = ultimaDataLST.advance(-29, 'day');
var fim30 = ultimaDataLST.advance(1, 'day');

var temp30 = lstC.filterDate(inicio30, fim30).mean().clip(urucui);
var tempCombinada30 =
temp30.reduce(ee.Reducer.mean()).rename('tempCombinada');

// Prioriza a janela de 7 dias e usa a de 30 dias apenas onde necessário.
var tempCombinada =
tempCombinada7.unmask(tempCombinada30).rename('tempCombinada');

// A escala 1000 m foi adotada por coerência com a resolução nominal do LST
MODIS.
var tStats = minMaxNorm(tempCombinada, 'tempCombinada', 1000);

// Maior temperatura = maior risco, portanto não há inversão aqui.
var tempNorm = tStats.norm.rename('tempNorm');

// -----
// 5. NDVI - SENTINEL-2 SR HARMONIZED
// -----

// Seleciona a coleção Sentinel-2 SR Harmonized para a área de estudo.
var s2Base = ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')
.filterBounds(urucui.geometry());

```

```
// Usa como referência temporal a imagem mais recente disponível.
var ultimaImagemS2 = ee.Image(s2Base.sort('system:time_start', false).first());
var endDate = ee.Date(ultimaImagemS2.get('system:time_start')).advance(1, 'day');

// Define duas janelas temporais:
// - 30 dias: composição principal
// - 60 dias: composição complementar para preencher lacunas
var start30 = endDate.advance(-30, 'day');
var start60 = endDate.advance(-60, 'day');

/**
 * maskS2SCL(img)
 * -----
 * Aplica máscara de qualidade a partir da banda SCL.
 *
 * O que remove:
 * - pixels sem dado
 * - saturados
 * - sombras
 * - nuvens médias/altas
 * - cirros
 * - neve/gelo
 *
 * Objetivo:
 * - melhorar a qualidade do NDVI final.
 */
function maskS2SCL(img) {
  var scl = img.select('SCL');
  var mask = scl.neq(0)
    .and(scl.neq(1))
    .and(scl.neq(3))
    .and(scl.neq(8))

```

```

    .and(scl.neq(9))
    .and(scl.neq(10))
    .and(scl.neq(11));
    return img.updateMask(mask);
}

// Gera duas coleções filtradas por qualidade.
var s2_30 = s2Base.filterDate(start30, endDate).map(maskS2SCL);
var s2_60 = s2Base.filterDate(start60, endDate).map(maskS2SCL);

// Compósitos medianos das bandas do NDVI.
var comp30 = s2_30.select(['B8', 'B4']).median();
var comp60 = s2_60.select(['B8', 'B4']).median();

// Calcula o NDVI para cada composição.
var ndvi30 = comp30.normalizedDifference(['B8', 'B4']).rename('NDVI');
var ndvi60 = comp60.normalizedDifference(['B8', 'B4']).rename('NDVI');

// Prioriza a janela de 30 dias e usa 60 dias como fallback.
var ndvi = ndvi30.unmask(ndvi60).rename('NDVI');

// Calcula mínimos e máximos do NDVI dentro da área de estudo.
var ndviStats = ndvi.reduceRegion({
  reducer: ee.Reducer.minMax(),
  geometry: urucui.geometry(),
  scale: 20,
  bestEffort: true,
  maxPixels: 1e13
});

var ndviMin = ee.Number(ndviStats.get('NDVI_min'));
var ndviMax = ee.Number(ndviStats.get('NDVI_max'));

```

```

var ndviDen = ndviMax.subtract(ndviMin).max(1e-6);

// Normaliza o NDVI.
var ndviNorm = ndvi.subtract(ndviMin).divide(ndviDen).clamp(0,
1).rename('ndviNorm');

// Inverte a lógica do NDVI.
// Menor vigor vegetativo / menor umidade da vegetação = maior risco.
var ndviRisco = ee.Image(1).subtract(ndviNorm).rename('ndviRisco');

// -----
// 6. TOPOGRAFIA - SRTM
// -----

// Seleciona o modelo digital de elevação SRTM.
var srtm = ee.Image('USGS/SRTMGL1_003').clip(urucui);

// -----
// 6.1 ALTITUDE
// -----

// Calcula mínimo e máximo de altitude na área de estudo.
var altStats = srtm.reduceRegion({
  reducer: ee.Reducer.minMax(),
  geometry: urucui.geometry(),
  scale: 30,
  bestEffort: true,
  maxPixels: 1e13
});
var altMin = ee.Number(altStats.get('elevation_min'));

```



```

var altMax = ee.Number(altStats.get('elevation_max'));
var altDen = altMax.subtract(altMin).max(1e-6);

// Normaliza a altitude.
var altNorm = srtm.subtract(altMin).divide(altDen).clamp(0, 1);

// Inverte a lógica da altitude.
// Neste modelo, áreas mais baixas são tratadas como mais suscetíveis.
var altRisco = ee.Image(1).subtract(altNorm).rename('altRisco');

// -----
// 6.2 DECLIVIDADE
// -----

// Deriva a declividade a partir do MDE.
var slope = ee.Terrain.slope(srtm).rename('slope');

// Padroniza entre 0 e 1.
// Quanto maior a declividade, maior a suscetibilidade.
var slopeNorm = slope.unitScale(0, 90).clamp(0, 1).rename('slopeNorm');

// -----
// 6.3 ORIENTAÇÃO DAS ENCOSTAS (ASPECTO)
// -----

// Deriva o aspecto (orientação da encosta).
var aspect = ee.Terrain.aspect(srtm).rename('aspect');

// Reclassifica o aspecto em classes de suscetibilidade.
// A lógica segue a metodologia adotada para o hemisfério sul,
// com maior risco em encostas voltadas para norte e menor
// risco nas voltadas para sul.

```

```

var aspectClass = aspect.expression(
  "(b('aspect') >= 337.5 || b('aspect') < 22.5) ? 5" + // Norte
  ": (b('aspect') >= 292.5 && b('aspect') < 337.5) ? 4" + // Noroeste
  ": (b('aspect') >= 247.5 && b('aspect') < 292.5) ? 4" + // Oeste
  ": (b('aspect') >= 22.5 && b('aspect') < 67.5) ? 3" + // Nordeste
  ": (b('aspect') >= 67.5 && b('aspect') < 112.5) ? 2" + // Leste
  ": (b('aspect') >= 112.5 && b('aspect') < 157.5) ? 2" + // Sudeste
  ": (b('aspect') >= 157.5 && b('aspect') < 202.5) ? 1" + // Sul
  ": (b('aspect') >= 202.5 && b('aspect') < 247.5) ? 1" + // Sudoeste
  ": 1"
).rename('aspectClass');

```

// Normaliza a classe do aspecto para a escala 0–1.

```

var aspectNorm = aspectClass.subtract(1).divide(4).clamp(0,
1).rename('aspectNorm');

```

// -----

// 7. PESOS AHP

// -----

// Pesos definidos pelo Processo de Análise Hierárquica (AHP).

// Esses valores representam a contribuição relativa de cada

// variável no índice final de risco.

```
var wPrec = 0.445; // precipitação
```

```
var wNDVI = 0.225; // NDVI
```

```
var wTemp = 0.213; // temperatura
```

```
var wSlope = 0.052; // declividade
```

```
var wAsp = 0.042; // aspecto
```

```
var wAlt = 0.023; // altitude
```

// Soma dos pesos.

```

// Mantida para garantir a normalização da combinação ponderada.
var wSum = wPrec + wNDVI + wTemp + wSlope + wAsp + wAlt;

// -----
// 8. ÍNDICE FINAL E CLASSIFICAÇÃO TEMÁTICA
// -----

// Combina as variáveis padronizadas por álgebra de mapas.
// Cada componente entra no cálculo multiplicado pelo seu peso.
var riscoIncendio = ee.Image(
  ndviRisco.multiply(wNDVI)
    .add(precipRisco.multiply(wPrec))
    .add(tempNorm.multiply(wTemp))
    .add(altRisco.multiply(wAlt))
    .add(slopeNorm.multiply(wSlope))
    .add(aspectNorm.multiply(wAsp))
).divide(wSum).rename('riscoIncendio');

// Converte o índice para percentual, facilitando a interpretação visual.
var riscoPercentual = riscoIncendio.multiply(100).rename('riscoPercentual');

// Classificação temática fixa do índice percentual.
// Essa classificação foi criada para facilitar a leitura do produto.
var classeRisco = riscoPercentual.expression(
  "(b('riscoPercentual') <= 25) ? 1" +
  ": (b('riscoPercentual') <= 50) ? 2" +
  ": (b('riscoPercentual') <= 75) ? 3" +
  ": 4"
).rename('classeRisco');
```

```
// -----
```

// 9. CAMADAS DE VISUALIZAÇÃO

```
// -----
```

```
// Paleta da classificação temática.
```

```
var paletaClasses = ['#fff7bc', '#fec44f', '#fe9929', '#cc4c02'];
```

```
// Paleta contínua do índice percentual.
```

```
var paletaContinua = ['#ffffcc', '#ffeda0', '#feb24c', '#f03b20', '#bd0026'];
```

```
// Cria a camada do limite municipal.
```

```
var limiteUrucui = ee.Image().byte().paint(urucui, 1, 2);
```

```
// Cria um efeito de sombreamento para dar contexto topográfico ao fundo do mapa.
```

```
var relevoSombreado = ee.Terrain.hillshade(srtm).clip(urucui);
```

```
// Camada de relevo sombreado.
```

```
mapa.addLayer(relevoSombreado, {
  min: 100,
  max: 255,
  palette: ['#f7f7f7', '#bdbdbd', '#636363']
}, 'Relevo sombreado', true, 0.22);
```

```
// Camada do índice contínuo percentual.
```

```
mapa.addLayer(riscoPercentual.clip(urucui), {
  min: 0,
  max: 100,
  palette: paletaContinua
}, 'Índice contínuo de risco (%)', false, 0.85);
```

```
// Camada classificada.
```

```
mapa.addLayer(classeRisco.clip(urucui), {
```

```

min: 1,
max: 4,
palette: paletaClasses
}, 'Classes do índice de risco (%)', true, 0.92);

```

```

// Limite municipal.
mapa.addLayer(limiteUrucui, {
  palette: ['#2f2f2f']
}, 'Limite municipal', true, 1);

```

```

// Camadas auxiliares desligadas por padrão, úteis para inspeção.
mapa.addLayer(acumulado15d.clip(urucui), {
  min: 0,
  max: 150,
  palette: ['#f7fbff', '#c6dbef', '#6baed6', '#2171b5']
}, 'Precipitacao acumulada (15 dias)', false);

```

```

mapa.addLayer(tempCombinada.clip(urucui), {
  min: 20,
  max: 45,
  palette: ['#313695', '#74add1', '#fee090', '#f46d43', '#a50026']
}, 'Temperatura combinada', false);

```

```

mapa.addLayer(ndvi.clip(urucui), {
  min: 0,
  max: 1,
  palette: ['#8c510a', '#d8b365', '#f6e8c3', '#c7eae5', '#5ab4ac', '#01665e']
}, 'NDVI', false);

```

```

mapa.addLayer(slope.clip(urucui), {
  min: 0,
  max: 20,

```

```
palette: ['#f7cf5', '#c7e9c0', '#74c476', '#238b45']
}, 'Declividade', false);
```

```
// -----
// 10. INTERFACE DO PRODUTO TÉCNICO
// -----
```

```
// Limpa a interface padrão e cria o painel lateral.
```

```
ui.root.clear();
```

```
var painel = ui.Panel({
  style: {
    width: '390px',
    padding: '18px 18px 14px 18px',
    backgroundColor: '#f8f6f1'
  }
});
```

```
// Título principal do produto.
```

```
var titulo = ui.Label('MAPA DE RISCO DE INCENDIOS FLORESTAIS', {
  fontSize: '20px',
  fontWeight: 'bold',
  color: '#2f2117',
  fontFamily: 'Georgia, serif',
  margin: '0 0 2px 0'
});
```

```
// Subtítulo com área de estudo.
```

```
var subtítulo = ui.Label('Uruçui, Piauí', {
  fontSize: '15px',
  fontWeight: 'bold',
```

```

color: '#5c4033',
fontFamily: 'Georgia, serif',
margin: '0 0 10px 0'
});

```

```
// Descrição sintética do produto.
```

```

var descricao = ui.Label(
  'Síntese espacial do risco potencial de incêndios florestais com base em análise
  multicritério ponderada pelo método AHP, integrando precipitação, temperatura de
  superfície, NDVI e atributos topográficos.',
  {
    fontSize: '12px',
    color: '#3f3f46',
    fontFamily: 'Georgia, serif',
    margin: '0 0 8px 0'
  }
);

```

```
// Créditos acadêmicos.
```

```

var autores = ui.Label(
  'Discente: Luiz Eduardo Araujo Silva\nOrientadora: Dra. Sammya Vanessa Chaves
  Vieira\nCoorientador: Dr. Edilson Livio Neves da Costa Carneiro',
  {
    fontSize: '11px',
    color: '#57534e',
    whiteSpace: 'pre',
    fontFamily: 'Georgia, serif'
  }
);

```

```
// Estilos gerais do painel.
```

```

var secaoStyle = {
  fontSize: '13px',

```

```
fontWeight: 'bold',
color: '#2f2117',
fontFamily: 'Georgia, serif',
margin: '10px 0 6px 0'
};
```

```
var textoStyle = {
  fontSize: '12px',
  color: '#333333',
  whiteSpace: 'pre',
  fontFamily: 'Georgia, serif',
  margin: '0 0 6px 0'
};
```

```
// Campos dinâmicos a serem preenchidos posteriormente.
```

```
var lblJanela = ui.Label('Carregando informações temporais...', textoStyle);
```

```
var lblResumoRisco = ui.Label('Calculando faixa do índice...', textoStyle);
```

```
// Exposição dos pesos do modelo.
```

```
var lblPesos = ui.Label(
  'Precipitação: 0.445\nNDVI: 0.225\nTemperatura: 0.213\nDeclividade:
0.052\nAspecto: 0.042\nAltitude: 0.023',
  textoStyle
);
```

```
// Explica a lógica da classificação temática do produto.
```

```
var lblMetodo = ui.Label(
  'Classificação temática do índice de risco em quatro classes percentuais para fins
de visualização do produto.',
  textoStyle
);
```

```
// Instrução para consulta pontual.
```



```
var lblClique = ui.Label(
    'Clique no mapa para consultar os valores do índice final e dos fatores
    normalizados em um ponto específico.',
    textoStyle
);
```

// Caixa que receberá as informações da consulta por clique.

```
var lblInspector = ui.Label('Aguardando seleção no mapa...', {
    fontSize: '12px',
    color: '#1f2937',
    whiteSpace: 'pre',
    fontFamily: 'Georgia, serif',
    backgroundColor: '#efe9df',
    padding: '10px',
    margin: '6px 0 0 0',
    border: '1px solid #ddd6cc'
});
```

// Rótulos da legenda temática.

```
var lblLegQ1 = ui.Label('Q1 - Risco baixo', {
    fontSize: '12px',
    color: '#2b2b2b',
    margin: '0 0 4px 0',
    fontFamily: 'Georgia, serif'
});
```

```
var lblLegQ2 = ui.Label('Q2 - Risco moderado', {
    fontSize: '12px',
    color: '#2b2b2b',
    margin: '0 0 4px 0',
    fontFamily: 'Georgia, serif'
});
```

```
var lblLegQ3 = ui.Label('Q3 - Risco alto', {  
    fontSize: '12px',  
    color: '#2b2b2b',  
    margin: '0 0 4px 0',  
    fontFamily: 'Georgia, serif'  
});
```

```
var lblLegQ4 = ui.Label('Q4 - Risco muito alto', {  
    fontSize: '12px',  
    color: '#2b2b2b',  
    margin: '0 0 4px 0',  
    fontFamily: 'Georgia, serif'  
});
```

```
// Montagem da interface lateral.
```

```
painel.add(titulo);  
painel.add(subtitulo);  
painel.add(descricao);  
painel.add(autores);  
painel.add(separador());
```

```
painel.add(ui.Label('Base temporal', secaoStyle));  
painel.add(lblJanela);  
painel.add(lblResumoRisco);  
painel.add(separador());
```

```
painel.add(ui.Label('Estrutura do modelo', secaoStyle));  
painel.add(lblPesos);  
painel.add(lblMetodo);  
painel.add(separador());
```

```

painel.add(ui.Label('Legenda temática', secaoStyle));
painel.add(linhaLegenda('#fff7bc', lblLegQ1));
painel.add(linhaLegenda('#fec44f', lblLegQ2));
painel.add(linhaLegenda('#fe9929', lblLegQ3));
painel.add(linhaLegenda('#cc4c02', lblLegQ4));
painel.add(separador());

painel.add(ui.Label('Consulta pontual', secaoStyle));
painel.add(lblClique);
painel.add(lblInspector);
painel.add(separador());

painel.add(ui.Label('Distribuição do índice (%)', secaoStyle));

// Histograma do índice percentual na área municipal.
var histograma = ui.Chart.image.histogram({
  image: riscoPercentual,
  region: urucui.geometry(),
  scale: 250,
  maxPixels: 1e13
}).setOptions({
  title: "",
  legend: {position: 'none'},
  colors: ['#8c2d04'],
  backgroundColor: '#f8f6f1',
  chartArea: {left: 55, right: 15, top: 10, bottom: 42},
  hAxis: {
    title: 'Risco (%)',
    titleTextStyle: {italic: false, bold: true, color: '#2f2117'},
    textStyle: {color: '#2f2117'}
  },
  vAxis: {

```

```

        title: 'Frequência',
        titleTextStyle: {italic: false, bold: true, color: '#2f2117'},
        textStyle: {color: '#2f2117'}
    }
});

painel.add(histograma);

// Rodapé informativo.
var rodape = ui.Label(
    'Elaboração: Google Earth Engine | Produto para fins de análise espacial e apoio à
    validação temática.',
    {
        fontSize: '10px',
        color: '#6b7280',
        fontFamily: 'Georgia, serif',
        margin: '10px 0 0 0'
    }
);

painel.add(rodape);

// Junta painel e mapa na interface final.
var layout = ui.SplitPanel(painel, mapa, 'horizontal', false);
ui.root.add(layout);

// -----
// 11. TEXTO DINÂMICO DO PAINEL
// -----

// Informa as janelas temporais efetivamente usadas nesta execução.

```

```

ee.Dictionary({
  lstData: ultimaDataLST.format('YYYY-MM-dd'),
  lstIni: inicio7.format('YYYY-MM-dd'),
  lstFim: fim7.advance(-1, 'day').format('YYYY-MM-dd'),
  chuvaData: ultimaDataChuva.format('YYYY-MM-dd'),
  chuvaIni: inicioChuva.format('YYYY-MM-dd'),
  chuvaFim: fimChuva.advance(-1, 'day').format('YYYY-MM-dd'),
  s2Ini: start30.format('YYYY-MM-dd'),
  s2Fim: endDate.advance(-1, 'day').format('YYYY-MM-dd')
}).evaluate(function(info) {
  lblJanela.setValue(
    'LST mais recente: ' + info.lstData + '\n' +
    'Janela principal de temperatura: ' + info.lstIni + ' a ' + info.lstFim + '\n\n' +
    'CHIRPS mais recente: ' + info.chuvaData + '\n' +
    'Janela de precipitação acumulada: ' + info.chuvaIni + ' a ' + info.chuvaFim + '\n\n'
  +
    'Janela principal do NDVI: ' + info.s2Ini + ' a ' + info.s2Fim
  );
});

// Mostra a amplitude do índice percentual no painel.
riscoPercentual.reduceRegion({
  reducer: ee.Reducer.minMax(),
  geometry: urucui.geometry(),
  scale: 250,
  bestEffort: true,
  maxPixels: 1e13
}).evaluate(function(stats) {
  lblResumoRisco.setValue(
    'Amplitude do índice final: ' +
    fmt(stats.riscoPercentual_min, 2) + '% a ' +
    fmt(stats.riscoPercentual_max, 2) + '%'
  );
});

```

```

);
});

// -----
// 12. CONSULTA POR CLIQUE
// -----

// Empilha as bandas que serão inspecionadas no ponto clicado.
var imagemConsulta = riscoIncendio.addBands([
    riscoPercentual,
    precipRisco,
    tempNorm,
    ndviRisco,
    slopeNorm,
    aspectNorm,
    altRisco,
    classeRisco
]);

// Camada que marcará o ponto consultado pelo usuário.
var pontoLayer = ui.Map.Layer(ee.Image().byte(), {palette: ['#1d4ed8']}, 'Ponto
consultado', false);
mapa.layers().add(pontoLayer);

// Evento de clique no mapa.
mapa.onClick(function(coords) {
    lblInspector.setValue('Consultando valores no ponto selecionado...');

    var ponto = ee.Geometry.Point([coords.lon, coords.lat]);
    var pontoFc = ee.FeatureCollection([ee.Feature(ponto)]);
    var pontoImg = ee.Image().byte().paint(pontoFc, 1, 4);

```

```

pontoLayer.setEeObject(pontoImg);
pontoLayer.setShown(true);

// Faz uma amostragem pontual na imagem empilhada.
var amostra = imagemConsulta.sample({
  region: ponto,
  scale: 250,
  numPixels: 1,
  geometries: false
}).first();

amostra.evaluate(function(feature) {
  if (!feature) {
    lblInspector.setValue(
      'Longitude: ' + fmt(coords.lon, 5) + '\n' +
      'Latitude: ' + fmt(coords.lat, 5) + '\n\n' +
      'Sem dados disponíveis para o ponto selecionado.'
    );
    return;
  }

  var p = feature.properties;

  // Traduz a classe numérica para o rótulo qualitativo.
  var classeTxt = p.classeRisco === 1 ? 'Q1 - Risco baixo' :
    p.classeRisco === 2 ? 'Q2 - Risco moderado' :
    p.classeRisco === 3 ? 'Q3 - Risco alto' :
    'Q4 - Risco muito alto';

  // Exibe no painel os valores do índice e dos fatores no ponto clicado.
  lblInspector.setValue(

```

```

'Longitude: ' + fmt(coords.lon, 5) + '\n' +
'Latitude: ' + fmt(coords.lat, 5) + '\n\n' +
'Índice final: ' + fmt(p.riscoIncendio, 3) + '\n' +
'Risco percentual: ' + fmt(p.riscoPercentual, 2) + '%\n' +
'Classe: ' + classeTxt + '\n\n' +
'Precipitação invertida: ' + fmt(p.precipRisco, 3) + '\n' +
'Temperatura normalizada: ' + fmt(p.tempNorm, 3) + '\n' +
'NDVI invertido: ' + fmt(p.ndviRisco, 3) + '\n' +
'Declividade normalizada: ' + fmt(p.slopeNorm, 3) + '\n' +
'Aspecto normalizado: ' + fmt(p.aspectNorm, 3) + '\n' +
'Altitude invertida: ' + fmt(p.altRisco, 3)
);
});
});

```

```

// -----
// 13. EXPORTAÇÃO
// -----

```

```

// Exporta o índice contínuo percentual.
// A saída vai diretamente para o Google Drive do usuário.
Export.image.toDrive({
  image: riscoPercentual.clip(urucui),
  description: 'Risco_Incendio_Urucui_Indice_Percentual',
  folder: 'GEE_Exports',
  fileNamePrefix: 'Risco_Incendio_Urucui_Indice_Percentual',
  region: urucui.geometry(),
  scale: 250,
  crs: 'EPSG:4326',
  maxPixels: 1e13
});

```



```

// Exporta a classificação temática do índice.
Export.image.toDrive({
  image: classeRisco.clip(urucui),
  description: 'Classes_Indice_Risco_Urucui',
  folder: 'GEE_Exports',
  fileNamePrefix: 'Classes_Indice_Risco_Urucui',
  region: urucui.geometry(),
  scale: 250,
  crs: 'EPSG:4326',
  maxPixels: 1e13
});

// -----
// 14. RESUMO NO CONSOLE
// -----

// Exibe informações de controle e auditoria do processamento.
print('===== RESUMO DO PROCESSAMENTO
=====');

print('LST - data mais recente:', ultimaDataLST.format('YYYY-MM-dd'));
print('LST - janela principal (7 dias):',
  inicio7.format('YYYY-MM-dd'),
  'a',
  fim7.advance(-1, 'day').format('YYYY-MM-dd')
);
print('Temperatura mínima (°C):', tStats.min);
print('Temperatura máxima (°C):', tStats.max);

print('Precipitação - data mais recente:', ultimaDataChuva.format('YYYY-MM-dd'));

```

```

print('Precipitação - janela 15 dias:',
      inicioChuva.format('YYYY-MM-dd'),
      'a',
      fimChuva.advance(-1, 'day').format('YYYY-MM-dd')
);
print('Precipitação acumulada mínima em 15 dias (mm):', pStats.min);
print('Precipitação acumulada máxima em 15 dias (mm):', pStats.max);

print('NDVI - janela principal (30 dias):',
      start30.format('YYYY-MM-dd'),
      'a',
      endDate.advance(-1, 'day').format('YYYY-MM-dd')
);
print('NDVI - janela complementar (60 dias):',
      start60.format('YYYY-MM-dd'),
      'a',
      endDate.advance(-1, 'day').format('YYYY-MM-dd')
);
print('NDVI mínimo:', ndviMin);
print('NDVI máximo:', ndviMax);

print('Altitude mínima (m):', altMin);
print('Altitude máxima (m):', altMax);

// Calcula amplitude do índice contínuo.
var riscoStats = riscoIncendio.reduceRegion({
  reducer: ee.Reducer.minMax(),
  geometry: urucui.geometry(),
  scale: 250,
  bestEffort: true,
  maxPixels: 1e13
});

```

```

// Calcula amplitude do índice percentual.
var riscoPctStats = riscoPercentual.reduceRegion({
  reducer: ee.Reducer.minMax(),
  geometry: urucui.geometry(),
  scale: 250,
  bestEffort: true,
  maxPixels: 1e13
});

print('Índice de risco mínimo:', ee.Number(riscoStats.get('riscoIncendio_min')));
print('Índice de risco máximo:', ee.Number(riscoStats.get('riscoIncendio_max')));
print('Risco percentual mínimo:',
ee.Number(riscoPctStats.get('riscoPercentual_min')));
print('Risco percentual máximo:',
ee.Number(riscoPctStats.get('riscoPercentual_max')));

// Resumos estatísticos adicionais das variáveis de entrada.
print('Resumo chuva (min/max/média):', resumoVariavel(acumulado15d, 5000));
print('Resumo temperatura (min/max/média):', resumoVariavel(tempCombinada,
1000));
print('Resumo NDVI (min/max/média):', resumoVariavel(ndvi, 20));
print('Resumo altitude (min/max/média):', resumoVariavel(srtm, 30));

```