

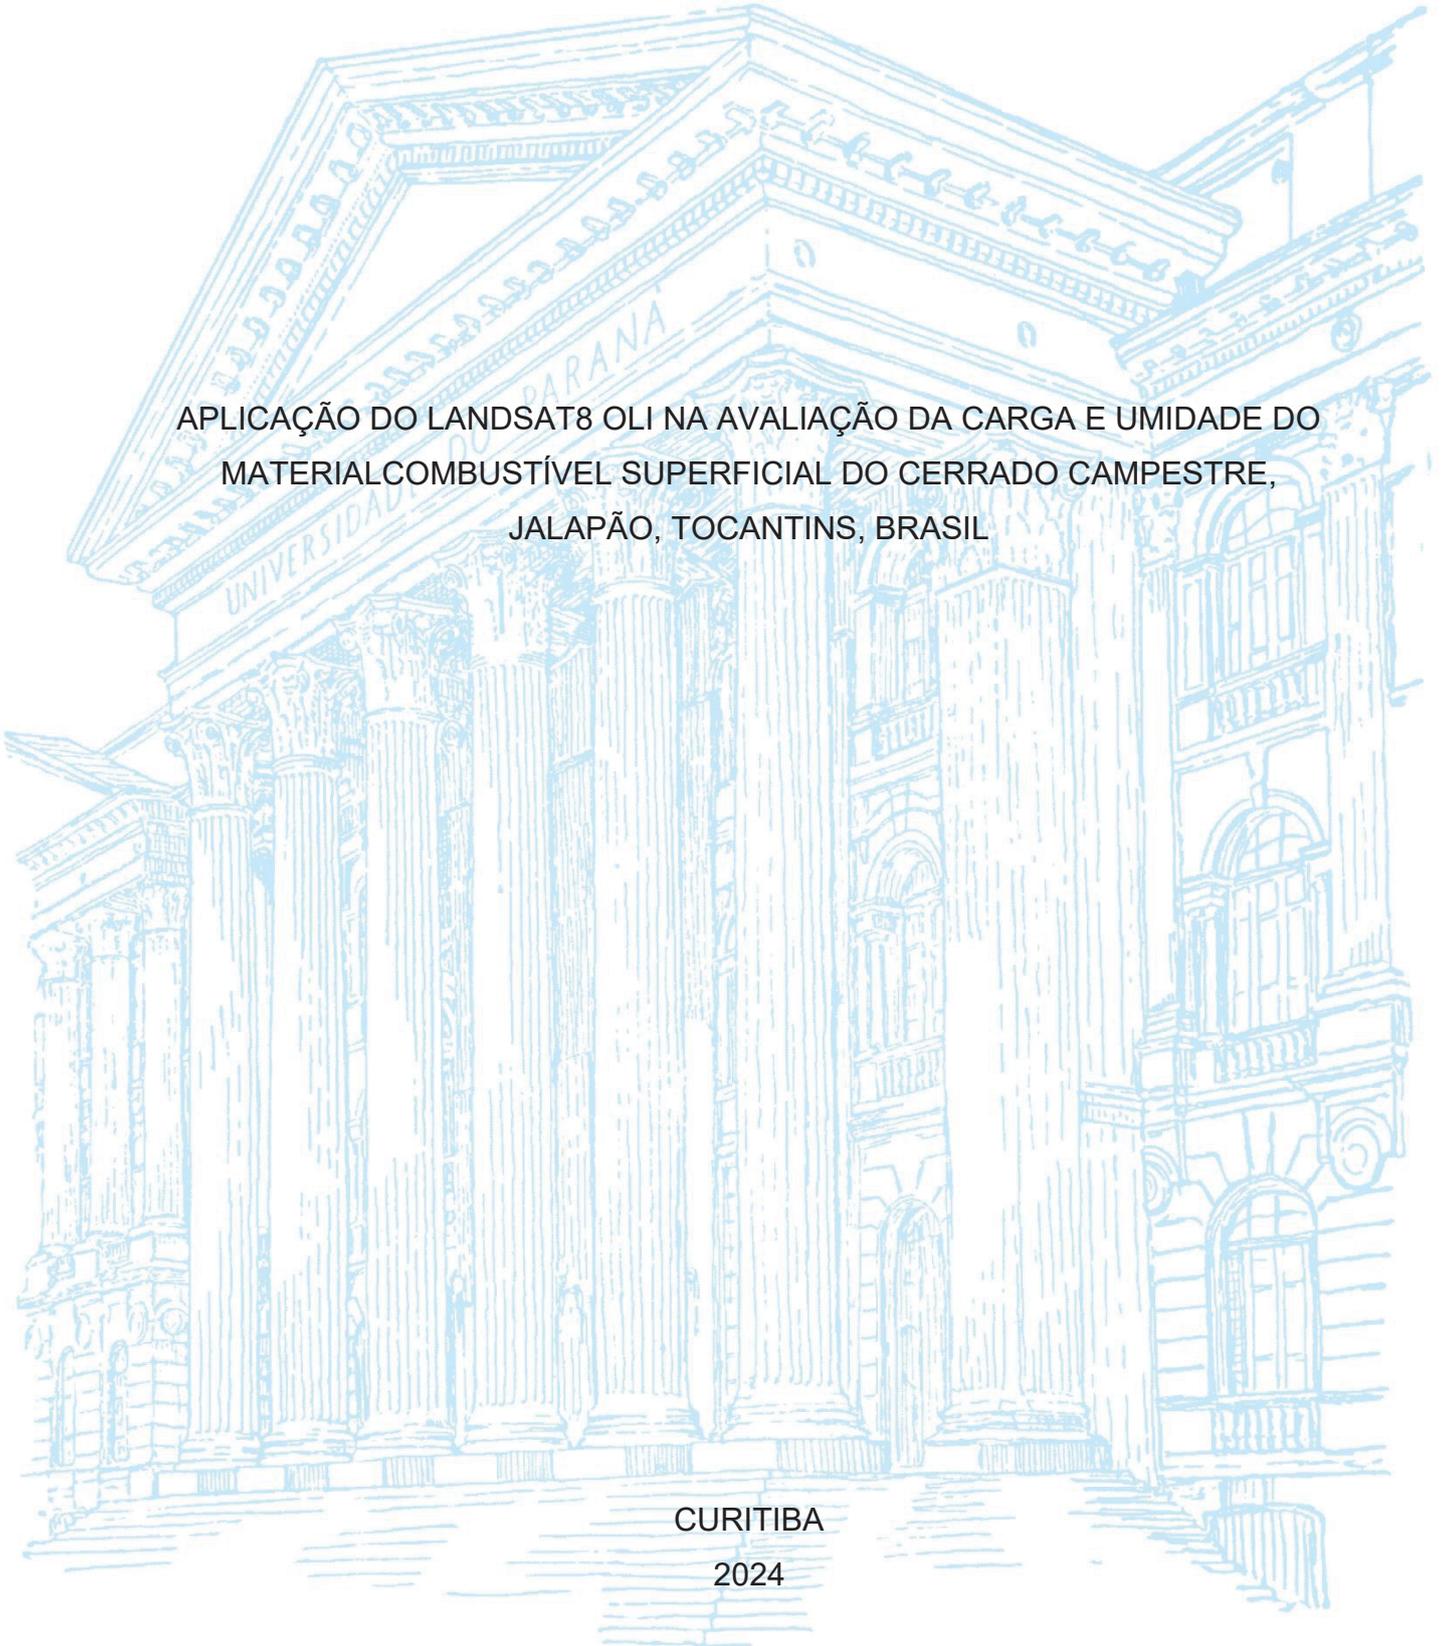
UNIVERSIDADE FEDERAL DO PARANÁ

MICAEL MOREIRA SANTOS

APLICAÇÃO DO LANDSAT8 OLI NA AVALIAÇÃO DA CARGA E UMIDADE DO
MATERIAL COMBUSTÍVEL SUPERFICIAL DO CERRADO CAMPESTRE,
JALAPÃO, TOCANTINS, BRASIL

CURITIBA

2024



MICAEL MOREIRA SANTOS

APLICAÇÃO DO LANDSAT 8 OLI NA AVALIAÇÃO DA CARGA E UMIDADE DO
MATERIAL COMBUSTÍVEL SUPERFICIAL DO CERRADO CAMPESTRE,
JALAPÃO, TOCANTINS, BRASIL

Tese apresentada ao Programa de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia Florestal.

Orientador: Prof. Dr. Antonio Carlos Batista
Coorientadora: Prof. Dra. Daniela Biondi Batista
Coorientador: Prof. Dr. Marcos Giongo

CURITIBA

2024

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Santos, Micael Moreira

Aplicação do Landsat8 OLI na avaliação da carga e umidade do material combustível superficial do cerrado campestre, Jalapão, Tocantins, Brasil / Micael Moreira Santos. - Curitiba, 2024.

1 recurso on-line : PDF.

Orientador: Prof. Dr. Antonio Carlos Batista

Coorientadores: Profa. Dra. Daniela Biondi Batista

Prof. Dr. Marcos Giongo

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 08/07/2024.

1. Sensoriamento remoto - Jalapão (TO : Microrregião). 2. LANDSAT (satélites) - Jalapão (TO : Microrregião). 3. Equações. 4. Algoritmos. 5. Incêndios florestais - Sensoriamento remoto. 6. Cerrados - Incêndios e prevenção de incêndio. I. Batista, Antonio Carlos. II. Batista, Daniela Biondi. III. Giongo, Marcos. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V . Título.

CDD – 634.9

CDU – 634.0.58(811.7)

Bibliotecária: Berenice Rodrigues Ferreira – CRB 9/1160



TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **MICAEL MOREIRA SANTOS** intitulada: **APLICAÇÃO DO LANDSAT 8 OLI NA AVALIAÇÃO DA CARGA E UMIDADE DO MATERIAL COMBUSTÍVEL SUPERFICIAL DO CERRADO CAMPESTRE, JALAPÃO, TOCANTINS, BRASIL.**, sob orientação do Prof. Dr. ANTONIO CARLOS BATISTA, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 08 de Julho de 2024.

Assinatura Eletrônica

10/07/2024 16:29:14.0

ANTONIO CARLOS BATISTA

Presidente da Banca Examinadora

Assinatura Eletrônica

09/07/2024 10:58:57.0

JADER NUNES CACHOEIRA

Avaliador Externo (UNIVERSIDADE FEDERAL DO TOCANTINS)

Assinatura Eletrônica

10/07/2024 11:37:46.0

JOSE FERNANDO PEREIRA

Avaliador Externo (UNIVERSIDADE FEDERAL DE TOCANTINS)

Assinatura Eletrônica

09/07/2024 14:47:51.0

ALEXANDRE FRANÇA TETTO

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

09/07/2024 13:17:37.0

ALEXANDRE BEUTLING

Avaliador Externo (UNIVERSIDADE FEDERAL DO MATO GROSSO DO SUL)

AGRADECIMENTOS

Primeiramente agradeço a Deus pelas infinitas bênçãos, por me conceder sabedoria e por me dar força e fé para concluir todas as etapas até aqui. Sem Deus nada disso teria acontecido.

À minha esposa Thyeiry Winny, que foi muito importante e sempre esteve ao meu lado me apoiando, amando, confortando e me ajudando a enfrentar os momentos de dificuldade.

Ao meu filho Miguel que é um dos meus maiores motivos para continuar lutando pelos meus objetivos e por todo o aprendizado que me proporciona mesmo sendo ainda uma criança.

A toda minha família, meus pais Orcina e Lindomar e irmã Milena pelo apoio, sustento e atenção a mim concedido em todos os momentos da minha vida.

Ao meu orientador, professor Dr. Antonio Carlos Batista, agradeço profundamente pela dedicação, pelos ensinamentos valiosos e pelas orientações constantes ao longo da realização do meu mestrado e doutorado.

A minha coorientadora, professora Dra. Daniela Biondi, pelas valiosas contribuições feitas na escrita de minha tese e realização das atividades do doutorado.

Ao meu coorientador, professor Dr. Marcos Giongo, agradeço por todas as oportunidades oferecidas, pelos ensinamentos e pelas orientações durante grande parte da minha graduação, assim como na realização do meu mestrado e doutorado.

Aos meus amigos e colegas de trabalho do Centro de Monitoramento Ambiental e Manejo do Fogo (CeMAF), em especial a Allan, Eduardo e Jader pelas experiências e conhecimentos obtidos durante os trabalhos realizados na ESEC e nas atividades diárias do CeMAF.

Aos gestores da ESEC Serra Geral do Tocantins, Ana Carolina, Marco Assis e Máximo Menezes, pela autorização e abertura das portas da ESEC e pelo amplo apoio no planejamento e execução dos trabalhos de campo.

Enfim, a todos que de alguma forma contribuíram e apoiaram na realização desta pesquisa, meu MUITO OBRIGADO!!!

“O Senhor firma os passos de um homem, quando a conduta deste o agrada.

Ainda que tropece, não cairá, pois o Senhor o toma pela mão”.

Salmos 37:23-24

RESUMO

O manejo eficaz do fogo no bioma Cerrado requer informações precisas sobre a carga e a umidade do combustível superficial, sendo essencial para o adequado manejo do combustível e para a tomada de decisões sobre queimas prescritas. Porém, técnicas e ferramentas para estimativas espaciais e temporais precisas desses parâmetros ainda são bastante escassas, principalmente em áreas campestres do Cerrado. A utilização de produtos de sensoriamento remoto, apresenta-se como uma solução promissora para suprir essa necessidade, permitindo a obtenção de informações de maneira eficiente e com menores custos. O presente estudo teve como principais objetivos: (1) avaliar a relação entre os produtos de Landsat 8 OLI e a carga e umidade do combustível superficial em áreas campestres do Cerrado durante a estação seca; (2) ajustar equações de regressão linear múltipla para estimar a carga de combustível; (3) estimar a carga de material combustível através dos algoritmos *Random Forest* e *k-Nearest Neighbors* (k-NN) e comparar com as estimativas realizadas pelas análises de regressão; e (4) determinar a importância das variáveis preditoras derivadas das imagens de satélite. O estudo foi conduzido na Estação Ecológica Serra Geral do Tocantins durante a estação seca (maio, junho, agosto e setembro), onde foram coletadas 64 unidades amostrais, com um distanciamento mínimo de 100 metros entre si. Para cada parcela de campo, foram extraídos valores medianos de uma janela de 3 x 3 *pixels* ao redor do *pixel* de referência. As análises de correlação linear de Pearson foram realizadas para avaliar a relação entre os dados de campo e as variáveis independentes derivadas das imagens de satélite. Adicionalmente, foram ajustados modelos de regressão linear múltipla, e algoritmos de *Random Forest* e k-NN foram aplicados para estimar a carga de combustível. Os resultados obtidos mostraram que as correlações mais fortes entre as variáveis de sensoriamento remoto e a carga e umidade do material combustível foram observadas para o combustível Herbáceo Morto. As correlações superiores incluíram a fração solo ($r = -0,81$ para carga e $r = -0,60$ para umidade) e a reflectância na região do infravermelho próximo ($r = -0,68$ para carga e $r = -0,61$ para umidade). Entre os índices de vegetação, os mais relevantes foram o MSI ($r = 0,77$ para carga e $r = 0,47$ para umidade), NDII6 e GVMI (ambos com $r = -0,77$ para carga), e correlações negativas com DER23 ($r = -0,57$) e MNDWI ($r = -0,56$) para umidade. Os modelos *Random Forest* apresentaram valores de R^2 variando de 0,52 a 0,83, superando as análises de regressão linear múltipla, cujos R^2 variaram de 0,63 a 0,78 e os valores de R^2 do algoritmo k-NN que variaram de 0,30 a 0,68. Pode-se concluir que o uso de dados de Landsat 8 OLI, especialmente através do algoritmo *Random Forest*, melhora significativamente a precisão das estimativas de carga de combustível superficial no Cerrado. As variáveis que exerceram maior influência nas estimativas foram a fração solo e os índices de vegetação que utilizam canais do infravermelho próximo e infravermelho de ondas curtas. Desta maneira, o sensoriamento remoto se mostra uma ferramenta de considerável importância para o manejo do fogo e a gestão de recursos naturais no Cerrado, oferecendo uma metodologia eficiente e economicamente viável para monitorar características do combustível superficial.

Palavras-chave: material combustível; imagens de satélite; análise de regressão; algoritmo de aprendizado de máquina

ABSTRACT

Effective fire management in the Cerrado biome requires accurate information about surface fuel load and moisture, essential for adequate fuel management and decision-making about prescribed burns. However, techniques and tools for precise spatial and temporal estimates of these parameters still need to be available, especially in rural areas of the Cerrado. Using remote sensing products presents a promising solution to meet this need, allowing information to be obtained efficiently and at lower costs. The main objectives of the present study were: (1) to evaluate the relationship between Landsat 8 OLI products and surface fuel load and moisture in grassland areas of the Cerrado during the dry season; (2) fit multiple linear regression equations to estimate fuel load; (3) estimate the load of combustible material using the Random Forest and k-Nearest Neighbors (k-NN) algorithms and compare with the estimates made by regression analyses; and (4) determine the importance of predictor variables derived from satellite images. The study was conducted at the Serra Geral do Tocantins Ecological Station during the dry season (May, June, August, and September). Sixty-four sampling units were collected, with a minimum distance of 100 meters between them. For each field plot, median values were extracted from a 3 x 3 pixel window around the reference pixel. Pearson linear correlation analyses evaluated the relationship between field data and independent variables derived from satellite images. Multiple linear regression models were also fitted, and Random Forest and k-NN algorithms were applied to estimate the fuel load. The results showed that the strongest correlations between the remote sensing variables and the load and moisture of the fuel material were observed for the Dead Herbaceous fuel. Top correlations included soil fraction ($r = -0.81$ for load and $r = -0.60$ for moisture) and near-infrared reflectance ($r = -0.68$ for load and $r = -0.61$ for moisture). Among the vegetation indices, the most relevant were MSI ($r = 0.77$ for load and $r = 0.47$ for humidity), NDII6 and GVMI (both with $r = -0.77$ for load), and negative correlations with DER23 ($r = -0.57$) and MNDWI ($r = -0.56$) for humidity. The Random Forest models presented R^2 values ranging from 0.52 to 0.83, surpassing the multiple linear regression analyses, whose R^2 varied from 0.63 to 0.78, and the R^2 values of the k-NN algorithm varied from 0.30 to 0.68. The study concludes that using Landsat 8 OLI data, primarily through the Random Forest algorithm, significantly improves the accuracy of surface fuel load estimates in the Cerrado. The variables that significantly influenced the estimates were the soil fraction and vegetation indices using near-infrared and short-wave infrared channels. In this way, remote sensing proves to be a tool of considerable importance for fire management and natural resource management in the Cerrado, offering an efficient and economically viable methodology for monitoring surface fuel characteristics.

Keywords: combustible material; satellite images; regression analysis; machine learning algorithm

LISTA DE FIGURAS

FIGURA 1 -	QUANTIDADE DE ARTIGOS PUBLICADOS DE 2009 A 2024 CONSIDERADNO A UTILIZAÇÃO DE SENSORIAMENTO REMOTO E <i>MACHINE LEARNING</i> PARA PREDIÇÕES DE VARIÁVEIS DE INCÊNDIOS FLORESTAIS.....	25
FIGURA 2 -	ÁREA DE ESTUDO E DISTRIBUIÇÃO DAS PARCELAS DE CAMPO	53
FIGURA 3 -	DELINEAMENTO EXPERIMENTAL UTILIZADO NAS COLETAS DE MATERIAL COMBUSTÍVEL	55
FIGURA 4 -	SÍNTESE DO PROCESSAMENTO DOS DADOS PROVENIENTES DO SENSORIAMENTO REMOTO.....	61
FIGURA 5 -	<i>BOXPLOTS</i> ABRANGENDO OS DADOS DE CARGA E UMIDADE DO MATERIAL COMBUSTÍVEL	64
FIGURA 6 -	CORRELAÇÕES ENTRE A CARGA DE COMBUSTÍVEL NAS DIFERENTES CLASSES E OS VALORES FRAÇÃO DA ANÁLISE DE MISTURA ESPECTRAL.....	66
FIGURA 7 -	CORRELAÇÕES ENTRE A CARGA DE COMBUSTÍVEL NAS DIFERENTES CLASSES E OS VALORES DE REFLECTÂNCIA DAS IMAGENS DE SATÉLITE	68
FIGURA 8 -	CORRELAÇÕES ENTRE A CARGA DE COMBUSTÍVEL EM SUAS DIFERENTES CLASSES E OS ÍNDICES DE VEGETAÇÃO CALCULADOS.....	70
FIGURA 9 -	FLUXOGRAMA DA METODOLOGIA APLICADA NO ESTUDO.....	89
FIGURA 10 -	MAPEAMENTO DE CARGA DE COMBUSTÍVEL UTILIZANDO O MELHOR MODELO <i>RANDOM FOREST</i> PARA COMBUSTÍVEL HERBÁCEO MORTO.....	101
FIGURA 11 -	MAPEAMENTO DE CARGA DE COMBUSTÍVEL UTILIZANDO OS MELHORES MODELOS <i>RANDOM FOREST</i> PARA COMBUSTÍVEL LENHOSO MORTO DE 1-H	102
FIGURA 12 -	MAPEAMENTO DE CARGA DE COMBUSTÍVEL UTILIZANDO OS MELHORES MODELOS <i>RANDOM FOREST</i> PARA COMBUSTÍVEL TOTAL MORTO <0,7 CM	103

FIGURA 13 -	MAPEAMENTO DE CARGA DE COMBUSTÍVEL UTILIZANDO OS MELHORES MODELOS <i>RANDOM FOREST</i> PARA COMBUSTÍVEL TOTAL <0,7 CM (VIVO E MORTO)	104
FIGURA 14 -	IMPORTÂNCIA DAS VARIÁVEIS DO MODELO DO ALGORITMO <i>RANDOM FOREST</i> COM MELHOR AJUSTE PARA ESTIMATIVA DE CARGA DE HERBÁCEO MORTO E LENHOSO MORTO DE 1-H	106
FIGURA 15 -	IMPORTÂNCIA DAS VARIÁVEIS DO MODELO DO ALGORITMO <i>RANDOM FOREST</i> COM MELHOR AJUSTE PARA ESTIMATIVA DE CARGA DE TOTAL MORTO <0,7 CM E TOTAL <0,7 CM (VIVO E MORTO)	107
FIGURA 16 -	MAPEAMENTO DA CONDIÇÃO FISIOLÓGICA DO COMBUSTÍVEL CONSTITUÍDO POR TRÊS IMAGENS FRAÇÃO DE <i>SUBPIXEL</i> (R: FVS; G: FVV; B: SOLO) NA ESTAÇÃO ECOLÓGICA SERRA GERAL DO TOCANTINS	110

LISTA DE TABELAS

TABELA 1 -	ÍNDICES DE VEGETAÇÃO CALCULADOS NO ESTUDO	58
TABELA 2 -	MÉTRICAS ESTATÍSTICAS DA VALIDAÇÃO CRUZADA REALIZADA PARA OS MELHORES AJUSTES FEITOS PARA A ESTIMATIVA DE CARGA ATRAVÉS DE VALORES DE FRAÇÃO DA METODOLOGIA DE MISTURA ESPECTRAL	94
TABELA 3 -	MÉTRICAS ESTATÍSTICAS DA VALIDAÇÃO CRUZADA REALIZADA PARA OS MELHORES AJUSTES FEITOS PARA A ESTIMATIVA DE CARGA ATRAVÉS DE VALORES DE REFLECTÂNCIA DAS BANDAS DO SENSOR OLI LANDSAT 8	95
TABELA 4 -	MÉTRICAS ESTATÍSTICAS DA VALIDAÇÃO CRUZADA REALIZADA PARA OS MELHORES AJUSTES FEITOS PARA A ESTIMATIVA DE CARGA ATRAVÉS DE VALORES DE ÍNDICES DE VEGETAÇÃO	96
TABELA 5 -	MÉTRICAS ESTATÍSTICAS DA VALIDAÇÃO CRUZADA REALIZADA PARA OS MELHORES AJUSTES FEITOS PARA A ESTIMATIVA DE CARGA ATRAVÉS DE TODAS AS VARIÁVEIS INDEPENDENTES DO ESTUDO	98
TABELA 6 -	MÉTRICAS ESTATÍSTICAS PARA AVALIAÇÃO DOS MODELOS GERADOS PELO ALGORITMO <i>RANDOM FOREST</i>	100
TABELA 7 -	VALORES DE K ESCOLHIDOS PARA CADA MODELO DO ALGORITMO K-NN	108
TABELA 8 -	MÉTRICAS ESTATÍSTICAS PARA AVALIAÇÃO DOS MODELOS GERADOS PELO ALGORITMO K-NN	108

LISTA DE ABREVIATURAS OU SIGLAS

EESGT	- Estação Ecológica Serra Geral do Tocantins
HV	- Combustível herbáceo vivo
HM	- Combustível herbáceo morto
LV1	- Combustível lenhoso vivo de 1-h
LV2	- Combustível lenhoso vivo de 10-h
LV3	- Combustível lenhoso vivo de 100-h
LM1	- Combustível lenhoso morto de 1-h
LM2	- Combustível lenhoso morto de 10-h
LM3	- Combustível lenhoso morto de 100-h
V07	- Combustível total vivo < 0,7 cm
M07	- Combustível total morto < 0,7 cm
Tot07	- Combustível total < 0,7 cm (vivo e morto)
CV%	- Coeficiente de variação percentual
R ² aj	- Coeficiente de determinação ajustado
RMSE	- Raiz do erro quadrático médio
MAE	- Erro médio absoluto
Syx	- Erro padrão da estimativa absoluto
Syx%	- Erro padrão da estimativa percentual
Dp	- Desvio padrão
dp R ²	- Desvio padrão do R ²
Ep	- Erro padrão
NDVI	- Índice de Vegetação por Diferença Normalizada
VARI	- Índice de Resistência Atmosférica Visível
Vl _{green}	- Índice Verde Visível
SR	- Razão simples
SIPI	- Índice de Pigmento Insensível à Estrutura
SAVI	- Índice de Vegetação Ajustado para o Solo
NDWI	- Índice de Água por Diferença Normalizada
NDII6	- Índice Infravermelho de Diferença Normalizada
NBR	- Taxa de Queima Normalizada
MVI	- Índice de Vegetação Modificado
MSR	- Razão Simples Modificada

MSI	- Índice de estresse de umidade
MNDWI	- Índice de Água Normalizado Modificado
INT	- Integral
GVMÍ	- Índice Global de Umidade da Vegetação
EVI	- Índice de Vegetação Aprimorado
DER ₅₆	- Derivado – banda 5 (ivp); banda 6 (siwir1)
DER ₄₅	- Derivado – banda 4 (vm); banda 5 (ivp)
DER ₃₄ -	- Derivado – banda 3 (vd); banda 4 (vm)
DER ₂₃ -	- Derivado – banda 2 (az); banda 3 (vd)

SUMÁRIO

	APRESENTAÇÃO.....	16
	INTRODUÇÃO	17
	CAPÍTULO 1 – VISÃO GERAL SOBRE MAPEAMENTOS DE VARIÁVEIS DE INCÊNDIOS FLORESTAIS UTILIZANDO TÉCNICAS DE GEOPROCESSAMENTO E <i>MACHINE LEARNING</i>	20
1	MAPEAMENTOS COM MÉTODOS DE APRENDIZADO DE MÁQUINA....	20
1.1	ALGORITMOS DE APRENDIZADO DE MÁQUINA	20
1.2	PLATAFORMA <i>GOOGLE EARTH ENGINE</i>	22
2	IMPORTÂNCIA DO SENSORIAMENTO REMOTO E <i>MACHINE LEARNING</i> PARA OS INCÊNDIOS FLORESTAIS.....	24
3	VARIÁVEIS DE INCÊNDIOS FLORESTAIS ESTIMADAS POR FERRAMENTAS DE <i>MACHINE LEARNING</i> E SENSORIAMENTO REMOTO.....	27
3.1	MAPEAMENTO DE ÁREA QUEIMADA	27
3.2	ESTIMATIVA DE CARGA DO COMBUSTÍVEL.....	29
3.3	ESTIMATIVA DE UMIDADE DO COMBUSTÍVEL.....	30
3.4	COMPORTAMENTO E SEVERIDADE DE INCÊNDIOS FLORESTAIS.....	32
3.5	TIPO DE MATERIAL COMBUSTÍVEL SUPERFICIAL	33
3.6	PERIGO E RISCO DE INCÊNDIOS FLORESTAIS	34
4	CONSIDERAÇÕES FINAIS	37
	REFERÊNCIAS.....	39
	CAPÍTULO 2 - RELAÇÕES ENTRE PRODUTOS DE LANDSAT 8 OLI E UMIDADE E CARGA DE MATERIAL COMBUSTÍVEL SUPERFICIAL EM AMBIENTE CAMPESTRE DE CERRADO	47
1	INTRODUÇÃO	49
1.1	HIPÓTESES	51
2	OBJETIVOS	52

2.1	OBJETIVO GERAL.....	52
2.2	OBJETIVOS ESPECÍFICOS	52
3	MATERIAL E MÉTODOS.....	53
3.1	ÁREA DE ESTUDO	53
3.2	LEVANTAMENTO DE CAMPO	54
3.3	OBTENÇÃO E PROCESSAMENTO DAS IMAGENS DE SATÉLITE	57
3.4	CÁLCULO DE ÍNDICES DE VEGETAÇÃO (IVS).....	58
3.5	ANÁLISE DE MISTURA ESPECTRAL	60
3.6	ANÁLISE ESTATÍSTICA DOS DADOS	62
4	RESULTADOS	63
4.1	CARGA E UMIDADE DO COMBUSTÍVEL	63
4.2	CORRELAÇÕES	65
4.2.1	Correlações envolvendo os valores fração da análise de mistura espectral	65
4.2.2	Correlações com valores de reflectância do sensor Landsat 8 OLI.....	67
4.2.3	Correlações envolvendo índices de vegetação (IVs).....	69
5	DISCUSSÃO	72
6	CONCLUSÕES	75
	REFERÊNCIAS.....	76
	CAPÍTULO 3 - ESTIMATIVA DA CARGA DO COMBUSTÍVEL SUPERFICIAL DE FITOFISIONOMIA CAMPESTRE DE CERRADO UTILIZANDO PRODUTOS DE LANDSAT 8 OLI.....	82
1	INTRODUÇÃO	84
1.1	HIPÓTESES	86
2	OBJETIVOS	87
2.1	OBJETIVO GERAL.....	87
2.2	OBJETIVOS ESPECÍFICOS	87
3	MATERIAL E MÉTODOS.....	88
3.1	ANÁLISE ESTATÍSTICA DOS DADOS	88

3.1.1	Análises de regressão linear múltiplas	88
3.1.2	Algoritmo <i>Random Forest</i>	90
3.1.3	Algoritmo <i>K-Nearest Neighbor</i>	91
3.1.4	Validação das equações de regressão lineares	92
4	RESULTADOS	93
4.1	ANÁLISES DE REGRESSÃO LINEAR MÚLTIPLAS	93
4.1.1	Ajustes em função dos valores fração da análise de mistura espectral.....	93
4.1.2	Ajustes em função dos valores de reflectância das imagens de satélite	94
4.1.3	Ajustes em função dos índices de vegetação.....	96
4.1.4	Ajustes em função de todas as variáveis independentes	97
4.2	ESTIMATIVAS UTILIZANDO O ALGORITMO <i>RANDOM FOREST</i>	99
4.2.1	Métricas de performance dos modelos.....	99
4.2.2	Importância das variáveis nos modelos <i>Random Forest</i>	105
4.2	ESTIMATIVAS UTILIZANDO O ALGORITMO <i>K-NEAREST NEIGHBOR</i> ..	107
5	DISCUSSÃO	109
6	CONCLUSÕES	115
	REFERÊNCIAS.....	116

APRESENTAÇÃO

A presente tese é composta por três capítulos com objetivos distintos, sendo que os capítulos foram escritos em formato de artigo científico. Com exceção do capítulo 1, que é uma revisão de literatura, os demais capítulos estão estruturados da seguinte forma: título; resumo; abstract; introdução; hipóteses; objetivos; material e métodos; resultados; discussão; conclusões e; referências.

No capítulo 1, intitulado “Visão geral sobre mapeamentos de variáveis de incêndios florestais utilizando técnicas de geoprocessamento e *machine learning*”, o objetivo foi realizar um levantamento de literatura dos trabalhos que realizam mapeamentos de variáveis relacionadas com incêndios florestais, em associação com técnicas de *machine learning* para predições indiretas dessas variáveis.

No capítulo 2, intitulado “Relações entre produtos de Landsat 8 OLI e umidade e carga de material combustível superficial em ambiente campestre de Cerrado”, o objetivo principal foi a avaliação das relações existentes entre os dados provenientes de Landsat 8 OLI e a carga e umidade do material combustível superficial durante a estação seca em ambiente campestre de Cerrado.

O capítulo 3, intitulado “Estimativa da carga do combustível superficial de fitofisionomia campestre de Cerrado utilizando produtos de Landsat 8 OLI” apresenta como objetivo principal foi avaliar o uso de produtos de imagens de Landsat 8 OLI para estimativa de carga de material combustível superficial campestre de Cerrado, considerando o período de seca, através de ajustes de equações de regressão linear múltiplas e aplicação de algoritmos *Random Forest* e *k-Nearest Neighbors*.

Desta maneira, espera-se com o presente estudo uma contribuição significativa para a gestão do fogo, com um melhor entendimento das relações e estimativas do material combustível por meio de imagens de satélite, em um importante bioma brasileiro, cujo conhecimento e informações sobre o tema são, ainda, bastante escassos.

INTRODUÇÃO

Os incêndios florestais são fenômenos naturais ou antropogênicos e que representam uma significativa ameaça às florestas e às comunidades de seu entorno, propagando-se rapidamente e causando danos consideráveis aos recursos naturais. Os incêndios florestais atuam como um importante fator de distúrbio nos ecossistemas, podendo alterar significativamente a estrutura e função da vegetação.

Neste sentido, o bioma Cerrado aparece como uma das maiores formações vegetais do Brasil, sendo caracterizado por uma alta biodiversidade e uma variedade de fitofisionomias, que vão desde as formações campestres, passando pelas formações savânicas, até às formações florestais, como é o caso dos Cerradões. Neste bioma, encontra-se uma alta ocorrência de incêndios florestais, especialmente nas áreas de fitofisionomias abertas em que as vegetações herbáceas e gramíneas são predominantes.

Os incêndios no Cerrado são classificados como incêndios superficiais, que consomem predominantemente os combustíveis finos presentes na camada de vegetação herbácea e arbustiva. Os incêndios nesse bioma desempenham um importante papel ecológico, tendo em vista que algumas de suas fitofisionomias são dependentes do fogo para o amplo desenvolvimento de seus papéis ecológicos e manutenção de sua biodiversidade. Porém, a ocorrência de frequentes e severos incêndios florestais tornam esses eventos uma ameaça significativa para esse bioma.

Localizada no centro do bioma Cerrado, na região do Jalapão, está a Estação Ecológica Serra Geral do Tocantins (EESGT), uma unidade de conservação de proteção integral muito importante para a realização de estudos científicos relacionados aos incêndios florestais, que busca entender melhor os processos ecológicos e os impactos do fogo no bioma. A gestão do fogo na EESGT é um desafio constante, que requer um conhecimento aprofundado das características do material combustível e das dinâmicas do fogo.

Nos últimos 10 anos, não apenas na EESGT como em outras áreas protegidas inseridas no bioma Cerrado, vem se desenvolvendo o Manejo Integrado e Adaptativo do Fogo (MIF), que propõe uma ideia de manejo do fogo de uma forma mais holística de maneira a incorporar as dimensões ecológicas, sociais, econômicas e culturais em escalas distintas. Dentre as diferentes atividades que estão associadas ao MIF, são realizadas queimas prescritas em períodos meteorológicos menos críticos, a fim de

favorecer queimas de menor intensidade e menos danosa a vegetação e, por consequência, diminuir a ocorrência de grandes e severos incêndios florestais. Em síntese, essas ações de manejo do fogo são, por conseguinte, ações de manejo do material combustível. Para que essa gestão do material combustível seja realizada de maneira eficaz e com menores custos é necessário a busca de novas ferramentas e aprimoramento das técnicas que já vem sendo utilizadas para esse fim.

O material combustível é um dos principais fatores intrínsecos do manejo do fogo, sendo o único que é passível de ser manipulado diretamente através da ação humana. A caracterização e quantificação desse material são essenciais para a compreensão do comportamento do fogo, facilitar a realização de queimas controladas, atividades de combate a incêndios e avaliação de riscos, além de permitir a modelagem de carbono. No entanto, a coleta de informações em campo para determinar as características do material combustível é complexa, demandando de considerável tempo e recursos. A utilização de métodos indiretos, como a modelagem biofísica, surge como uma alternativa viável para estimar parâmetros de difícil mensuração direta.

Em paralelo a utilização de métodos indiretos para obtenção de parâmetros da vegetação, o uso de técnicas de sensoriamento remoto surge como uma solução eficiente e econômica para a estimativa e classificação de atributos do material combustível. Os produtos derivados do sensoriamento remoto podem ser utilizados em estimativas do conteúdo de umidade do combustível, da biomassa herbácea, da condição do combustível (vivo ou morto) e classificações de tipos de combustível, bem como vêm sendo utilizados para diferentes avaliações do fogo, como a avaliação do risco e perigo de incêndios florestais, severidade do fogo, dentre outras.

Diversos estudos exploram essa relação entre produtos de sensoriamento remoto e características do combustível superficial, incluindo a aplicação de análise de mistura espectral e índices de vegetação, além de técnicas com sensores LiDAR e radar. No entanto, no que se refere ao ambiente de Cerrado em fitofisionomias campestres, os conhecimentos dessas relações ainda são pouco abordados. Grande parte dos estudos realizados se concentram na caracterização de variáveis florestais, sendo que poucos focam nas variáveis de combustíveis superficiais, que estão mais relacionadas à ocorrência de incêndios superficiais no Cerrado.

Dada a importância do sensoriamento remoto para a determinação indireta do material combustível e melhoria das estratégias de manejo do fogo, é importante

destacar que as abordagens tradicionais que proporcionam a integração entre as informações de campo e dados de sensoriamento remoto, vem sendo modificados através do advento das técnicas de *machine learning*, ou, algoritmos de aprendizado de máquina. Algoritmos de *machine learning* podem ser utilizados na identificação de padrões e relações complexas nos dados, o que permite a criação de modelos preditivos mais precisos e robustos.

No caso dos incêndios florestais, como exemplo, as técnicas de *machine learning* podem ser aplicadas para melhorar as estimativas das características do material combustível, considerando a alta variabilidade espacial e temporal presente no bioma Cerrado. Modelos baseados em *machine learning* podem integrar dados de diferentes fontes, como imagens de satélite e dados meteorológicos, para prever a umidade do combustível e o risco de incêndio com uma maior precisão, dentre outras aplicações.

Contudo, a combinação de técnicas de sensoriamento remoto e *machine learning*, surge como potencial de melhoria da gestão dos incêndios florestais no bioma Cerrado. O avanço no estudo científico para aprimoramento dessas tecnologias é fundamental para o desenvolvimento de estratégias de manejo do fogo mais eficazes, que considerem a complexidade e a dinâmica dos ecossistemas de Cerrado. Esses estudos devem ser contínuos com o objetivo de explorar e integrar diferentes abordagens e metodologias para proporcionar uma base científica robusta que apoie a conservação e a gestão sustentável deste importante e rico bioma.

CAPÍTULO 1 – VISÃO GERAL SOBRE MAPEAMENTOS DE VARIÁVEIS DE INCÊNDIOS FLORESTAIS UTILIZANDO TÉCNICAS DE GEOPROCESSAMENTO E *MACHINE LEARNING*

1 MAPEAMENTOS COM MÉTODOS DE APRENDIZADO DE MÁQUINA

1.1 ALGORITMOS DE APRENDIZADO DE MÁQUINA

O aprendizado de máquina (*machine learning*) é uma categoria de algoritmos que permite aos computadores aprenderem a partir de dados sem programação explícita, ajudando a encontrar padrões ocultos em grandes conjuntos de dados (YANGLI-AO GENG et al., 2019). A utilização de algoritmos de aprendizado de máquina tem sido amplamente utilizada em diversas áreas ambientais, proporcionando avanços significativos na modelagem, monitoramento e previsão de fenômenos ambientais. Como exemplo, a utilização de algoritmos como Árvores de Decisão (*Decision Tree*) e Máquinas de Vetores de Suporte (*Support Vector Machine - SVM*) têm sido utilizados para monitorar a qualidade da água em estações de tratamento. Jalal; Ezzedine (2019) analisaram o desempenho desses algoritmos para um sistema de monitoramento da qualidade da água em uma estação de tratamento na Tunísia, mostrando a eficácia desses métodos para a detecção e classificação de dados de qualidade da água.

A qualidade do ar é outra área onde técnicas de *machine learning* tem mostrado grande potencial. Algoritmos de aprendizado de máquina podem ser adotados para monitoramento da qualidade do ar utilizando imagens de satélite e dados de dispositivos sensores. Como exemplo, Zaytar e El Amrani (2020) destacam como essas técnicas podem ser usadas para prever níveis de poluição do ar e identificar padrões de poluição em diferentes regiões. Enquanto Kanevski et al. (2004) demonstram a aplicação de algoritmos como *Perceptron* Multicamadas, Máquinas de Vetores de Suporte (SVM) e Redes Neurais de Regressão Geral, juntamente com a aplicação de geoestatística para resolver problemas ambientais orientados para a tomada de decisões e modelagem ambiental.

No campo da agricultura, algoritmos de aprendizado de máquina são aplicados para monitoramento de plantas, análise de solo, processos de

detecção/predição e monitoramento de animais. Araújo et al. (2023) apresentam diferentes abordagens no âmbito da agricultura acerca de como técnicas podem aumentar a produção agrícola e enfrentar desafios como o aquecimento global e a falta de mão-de-obra. Bai et al. (2021) utilizaram abordagens baseadas em aprendizado de máquina para melhorar as estimativas de evapotranspiração em terras agrícolas, mostrando como esses métodos podem ser aplicados em diferentes condições ambientais. Han e Wang (2021) revisaram o uso de técnicas de redes neurais artificiais para a previsão de vários problemas ambientais, mostrando sua ampla aplicabilidade em diferentes áreas ambientais.

As técnicas de *machine learning* também têm sido amplamente utilizados na gestão de incêndios florestais, contribuindo significativamente para a previsão, detecção e gerenciamento do comportamento do fogo, bem como, tem se desenvolvido para o manejo do combustível. A utilização de técnicas de sensoriamento remoto em associação com técnicas *machine learning* podem ser aplicados na estimativa de biomassa de florestas, plantios florestais, sistemas agroflorestais, podendo, também, ser estendido para a gestão de incêndios florestais. Thapa, Lovell e Wilson (2023) revisaram aplicações dessas técnicas em sistemas agroflorestais, destacando fortemente seu potencial de utilização em outros contextos.

Estudos vem demonstrando que a utilização de algoritmos de *machine learning* melhora a precisão das estimativas de biomassa florestal quando combinados com dados de sensoriamento remoto multissensores. Essas técnicas permitem um melhor entendimento das características da biomassa e uma modelagem mais precisa em diferentes tipos de florestas. Nguyen e Kappas (2020) estimaram biomassa acima do solo de uma área florestal, utilizando dados do satélite SPOT-6 e o algoritmo *Random Forest*, concluindo o potencial do algoritmo para estimativa da biomassa florestal. Também para estimativa de biomassa acima do solo, Singh et al. (2022) utilizam de quatro técnicas de aprendizado de máquina (ML) para estimativa de biomassa com base em dados de satélite e levantamentos de campo. As técnicas ML utilizadas pelos autores foram k-Nearest Neighbor (k-NN), *Support Vector Machine* (SVM), *Artificial Neural Network*, e *Random Forest* (RF). Na mesma linha de pesquisa Ghosh e Behera (2018) utilizaram os algoritmos *Random Forest* e *Stochastic Gradient Boosting* (SGB), em que ambos se mostraram eficazes para estimativa da biomassa acima do solo em florestas tropicais.

1.2. PLATAFORMA GOOGLE EARTH ENGINE

A plataforma *Google Earth Engine* (GEE) é baseada em computação em nuvem para a análise geoespacial em escala planetária. Lançada em 2010, o GEE combina o poder computacional da Google com um repositório de dados geoespaciais massivos, possibilitando a análise de questões ambientais de impacto, como desmatamento, secas, desastres naturais e mudanças climáticas (GORELICK et al., 2017). A utilização do GEE permite a realização de análises de considerável complexidade em grandes volumes de dados de forma rápida e eficiente, sem a necessidade de recursos computacionais avançados por parte do usuário (TAMIMINIA et al., 2020). A plataforma fornece interfaces de programação de aplicativos (APIs) em *JavaScript* e *Python*, facilitando a integração com outras ferramentas e bibliotecas de *software*. Isso permite aos desenvolvedores criarem aplicativos personalizados e realizar análises detalhadas (REIS; DATIA; PATO, 2020).

O GEE tem sido amplamente utilizado para monitorar e analisar mudanças no uso da terra, desmatamento, saúde das florestas e impactos das mudanças climáticas. As séries temporais de dados de satélite permitem a detecção de tendências e a avaliação de políticas ambientais (ZHAO et al., 2021). A utilização do GEE tem sido instrumental em projetos de monitoramento do desmatamento, fornecendo dados atualizados que ajudam na tomada de decisões para a conservação das florestas tropicais e temperadas (CHEN et al., 2021).

Um estudo de Arai et al. (2019) utilizou o GEE para realizar a detecção e fazer a análise da degradação florestal causada por incêndios na Amazônia Brasileira. Usando imagens do Landsat 8 OLI, foi possível realizar o monitoramento das mudanças na cobertura florestal ao longo do tempo e identificar áreas afetadas pelo fogo. Chen et al. (2021) demonstraram o uso do GEE para monitoramento da degradação florestal em regiões temperadas, como a Geórgia. Através da análise de séries temporais de dados Landsat, o estudo foi capaz de estimar a área de degradação florestal com considerável precisão, demonstrando, portanto, a eficácia do GEE em diferentes biomas.

O *Google Earth Engine* tem se mostrado uma plataforma essencial para a análise, gestão e manejo de incêndios florestais. A capacidade dessa plataforma de integrar grandes volumes de dados geoespaciais, aplicar técnicas avançadas de aprendizado de máquina e oferecer ferramentas analíticas robustas permite que

pesquisadores e gestores ambientais monitorem e respondam de forma eficiente aos incêndios florestais. Estudos como o de Velizarova et al. (2019) aplicam técnicas de sensoriamento remoto e dados climáticos para monitorar regiões vulneráveis aos incêndios florestais, demonstrando correlações significativas com parâmetros climáticos, como a precipitação média e a umidade relativa do ar. O uso do *Google Earth Engine* foi uma ferramenta de fundamental importância no estudo de Silva-Cardoza et al. (2022), proporcionando uma plataforma para o processamento de dados de sensoriamento remoto, cálculo de índices espectrais, implementação de correções fenológicas e validação de modelos de severidade de incêndios. Toda essa combinação de funcionalidades foi capaz de permitir uma análise mais detalhada e precisa da severidade dos incêndios florestais.

2 IMPORTÂNCIA DO SENSORIAMENTO REMOTO E MACHINE LEARNING PARA OS INCÊNDIOS FLORESTAIS

A gestão de incêndios florestais se apresenta como um desafio enfrentado por muitos países ao redor do mundo, particularmente devido às mudanças climáticas que têm aumentado a frequência e a intensidade desses eventos. O uso de sensoriamento remoto fornece uma ampla gama de dados de alta resolução espacial e temporal, essenciais para modelagem do comportamento do fogo. Técnicas como LiDAR, RADAR e imagens multiespectrais e hiperespectrais capturadas por satélites e drones são utilizadas para mapear a estrutura da vegetação, a densidade de combustível e a umidade da vegetação. O sensoriamento remoto associado com técnicas de aprendizado de máquina vem se tornando uma ferramenta essencial para a gestão de incêndios florestais, considerando a obtenção de variáveis e análise de dados (SANTOS et al., 2023).

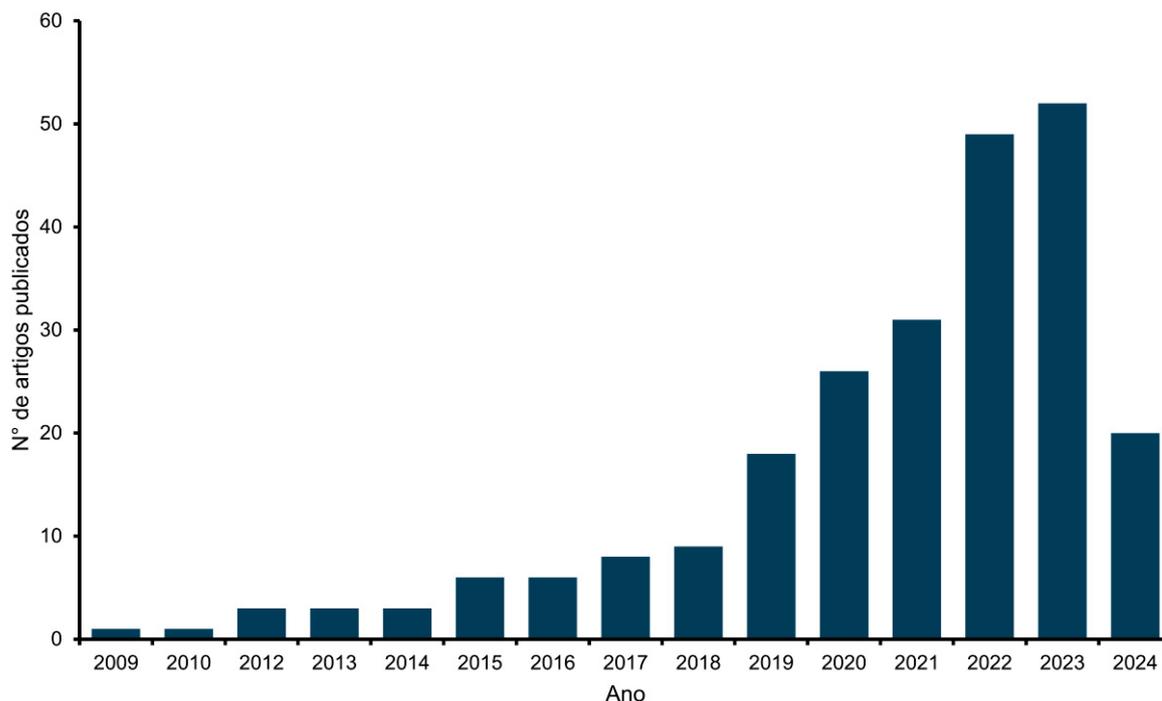
O *machine learning*, por sua vez, aprimora a análise dos dados coletados, permitindo a criação de modelos preditivos que identificam áreas de alta suscetibilidade a incêndios. Modelos como o *Multivariate Adaptive Regression Splines* (MARS), *Support Vector Machine* (SVM) e *Boosted Regression Tree* (BRT) têm mostrado alta precisão na previsão de incêndios florestais, utilizando variáveis como índices de vegetação, fatores climáticos, topografia e características ambientais (KALANTAR et al., 2020).

Essa combinação oferece melhorias significativas na detecção, monitoramento e mitigação dos incêndios florestais. A utilização de técnicas de sensoriamento remoto permite a coleta de dados extensivos e em tempo real sobre variáveis como a umidade do solo, a densidade da vegetação e as condições atmosféricas, fundamentais para a análise do perigo de incêndios. O aprendizado de máquina (*machine learning*) se apresenta como uma ferramenta com considerável capacidade para processar e interpretar esses conjuntos de dados, permitindo identificar padrões complexos e correlacionando variáveis ambientais com probabilidade de ocorrência de incêndios. Algoritmos como Redes Neurais, *Random Forest* e *Support Vector Machines* são treinados para analisar dados de sensoriamento remoto e podem fornecer previsões precisas sobre o comportamento e severidade do fogo (GHALI; AKHLOUFI, 2023).

Como exemplo da importância dessas ferramentas, Li, Lai e Quan (2022) desenvolveram um método que combina modelos de transferência radiativa com *perceptrons* multicamadas para estimar a carga de combustível de folhagem de copas (FFL) a partir de dados Landsat. Esse método demonstrou ser mais eficiente do que as abordagens tradicionais de *lookup table*, destacando-se na avaliação do perigo de incêndios florestais.

Na Figura 1 é apresentado graficamente o comportamento das publicações científicas que utilizam de técnicas de sensoriamento remoto em combinação com algoritmos de aprendizado de máquina para previsões de variáveis associadas aos incêndios florestais. É perceptível que os estudos envolvendo o tema vem crescendo, principalmente do ano de 2019 em diante, demonstrando a importância que essa abordagem vem tendo nos últimos anos.

FIGURA 1 - QUANTIDADE DE ARTIGOS PUBLICADOS DE 2009 A 2024 CONSIDERANDO A UTILIZAÇÃO DE SENSORIAMENTO REMOTO E *MACHINE LEARNING* PARA PREVISÕES DE VARIÁVEIS DE INCÊNDIOS FLORESTAIS



FONTE: Web of Science (2024).

Para a detecção e monitoramento dos incêndios florestais em imagens de satélite, métodos de segmentação e detecção de incêndios baseados em *deep learning* vem sendo desenvolvidos nos últimos anos. Ambos os métodos mostraram

um resultado interessante em comparação com os métodos tradicionais de *machine learning*, além de serem de utilidade para uma gestão eficiente do fogo. A detecção de incêndio se concentra em identificar a presença de fogo (fumaça, chama ou ambos) e classificá-lo, enquanto a segmentação de incêndio é o processo de agrupar *pixels* semelhantes de fumaça ou chama em uma imagem de satélite de entrada com base em suas características, como cor, forma e textura, gerando o resultado como uma máscara (GHALI; AKHLOUFI, 2023).

Além disso, essa combinação entre sensoriamento remoto e *machine learning* permite a criação de sistemas de alerta e a automação de processos de tomada de decisão. A criação desses sistemas pode fornecer informações valiosas para autoridades e gestores públicos, contribuindo para um melhor e mais eficiente direcionamento dos recursos e a desenvolver estratégias de mitigação mais eficazes para diferentes casos (MOHAJANE et al., 2021).

3 VARIÁVEIS DE INCÊNDIOS FLORESTAIS ESTIMADAS POR FERRAMENTAS DE *MACHINE LEARNING* E SENSORIAMENTO REMOTO

3.1 MAPEAMENTO DE ÁREA QUEIMADA

O mapeamento de áreas afetadas pelo fogo é uma tarefa de importância para o entendimento da extensão e os impactos dos incêndios florestais. A combinação entre técnicas de aprendizado de máquina (*machine learning*) com informações de sensoriamento remoto vem se apresentando como uma abordagem eficaz para essa finalidade. Diferentes pesquisas têm explorado essa sinergia a fim de melhorar a precisão e a eficiência na detecção e mapeamento de áreas queimadas.

Os trabalhos que envolvem a utilização de *machine learning* e técnicas de sensoriamento remoto para o mapeamento de áreas queimadas têm demonstrado avanços significativos na precisão e eficiência dessas técnicas. Prabowo et al. (2022) atuaram no desenvolvimento de um conjunto de dados específico para treinamento e avaliação de modelos U-Net, delineando manualmente áreas queimadas em imagens Landsat 8 na Indonésia. Esse conjunto de dados facilita a detecção, segmentação e classificação de áreas queimadas utilizando *deep learning*. Negri et al. (2022) introduziram uma metodologia unificada, que combina séries temporais de imagens multiespectrais de satélites Landsat 8, Sentinel 2 e Terra, juntamente com modelagem estatística e classificação não supervisionada para mapeamentos de áreas queimadas. A metodologia provou ser eficaz, com altas precisões e reduções de ruído nas imagens mapeadas.

Cabe destacar o trabalho de Arai et al. (2019) que utilizaram imagens de Landsat 8 OLI no *Google Earth Engine* (GEE) para a detecção e análise da degradação florestal por incêndios na Amazônia. Tal abordagem permitiu identificar áreas afetadas pelo fogo e realizar o monitoramento da recuperação da vegetação após os incêndios, demonstrando a eficácia das técnicas de sensoriamento remoto em extensas áreas florestais. Também em área Amazônica, Bem et al. (2020) avaliaram a utilização de redes neurais convolucionais (CNNs) para mapeamento do desmatamento e áreas queimadas. Utilizando dados do Landsat e por meio da plataforma GEE, o estudo alcançou melhor desempenho comparado a algoritmos tradicionais como *Random Forest* e *Perceptron* multicamada. Tal pesquisa ressalta a

capacidade das CNNs em obter características complexas das imagens de satélite, melhorando a precisão na detecção de áreas queimadas.

Utilizando dados de Landsat, Chen et al. (2021) utilizaram séries temporais no GEE para monitorar a degradação florestal em regiões temperadas. O uso de técnicas de aprendizado de máquina contribuiu para realizar estimativas da área degradada com alta precisão, detalhando acerca da severidade dos incêndios e a extensão das áreas afetadas. O estudo exemplifica como a análise de séries temporais pode ser crucial para entender a dinâmica dos incêndios florestais ao longo do tempo. Santos et al. (2023) utilizaram de técnicas de sensoriamento remoto em associação com algoritmos de aprendizado de máquina, por meio de análise harmônica de Fourier e o classificador *Random Forest*, para mapear extensas áreas queimadas no noroeste de Portugal. O estudo destacou a precisão e a eficiência na detecção de áreas queimadas ao longo de um período de 20 anos.

Neste sentido, Sherstjuk, Zharikova e Sokol (2018) demonstraram como a combinação entre veículos aéreos não tripulados (VANTs) com imagens de satélite pode aumentar a eficiência na previsão e resposta a incêndios florestais. Os VANTs equipados com sensores espectrais e térmicos atuam de forma complementar aos dados de satélite, fornecendo informações detalhadas com uma alta resolução sobre as áreas queimadas. O estudo de Pinto et al. (2020) explorou a utilização de redes neurais para mapeamento de áreas queimadas através de séries temporais de imagens de satélite. O modelo que foi proposto pelo estudo conseguiu resultados significativos em diferentes regiões, validando a eficácia do *deep learning* para mapeamento de áreas queimadas. Stroppiana et al. (2021), em uma abordagem automática desenvolvida para o mapeamento de áreas queimadas utilizando dados de Sentinel 2, utilizaram uma metodologia que combina aprendizado de máquina com o algoritmo *Region Growing*, resultando em mapas com alta precisão de áreas queimadas com baixa taxa de erros de omissão e comissão.

Segundo Hu, Ban e Nascetti (2021), o uso de arquiteturas de redes neurais como U-Net e HRNet com imagens de Sentinel 2 e Landsat 8 demonstrou uma considerável precisão ao mapear áreas queimadas. Tais modelos aproveitam informações contextuais e capturam detalhes espaciais em múltiplas escalas. Bellenguer-Plomer et al. (2021) analisaram o uso de redes neurais convolucionais (CNN) com o objetivo de mapear áreas queimadas em associação com dados ópticos

e de radar dos satélites Sentinel 1 e Sentinel 2. A integração dessas informações permitiu o mapeamento eficaz mesmo em condições com cobertura de nuvens.

3.2 ESTIMATIVA DE CARGA DO COMBUSTÍVEL

Com um enorme reservatório de carbono, o ecossistema florestal desempenha um papel na redução do aquecimento global. A maioria das atividades relacionadas às avaliações de biomassa florestal concentra-se na biomassa acima do solo (*Aboveground Biomass - AGB*) de árvores vivas porque a AGB representa a maior quantidade de biomassa total nas florestas. Avaliações precisas dos estoques florestais de AGB e seus padrões espaço-temporais são relevantes para o manejo sustentável das florestas. Estimar o AGB é uma das etapas mais importantes na medição e avaliação dos estoques de carbono e do sequestro de carbono das florestas (PANDIT; TSUYUKI; DUBE, 2018).

Os trabalhos que estimam a carga de combustível utilizando algoritmos de aprendizado de máquina demonstram a eficiência e precisão dessas técnicas em diferentes contextos. Em estudo realizado por D'este et al. (2021) foram desenvolvidos modelos que combinam dados de sensoriamento remoto multiespectral (Sentinel 2), SAR (Sentinel 1) e LIDAR para estimar a carga de combustível fino morto, em que o *Random Forest* se mostrou o mais eficaz. Outro estudo de De Castro et al. (2022) utilizou imagens de satélite Sentinel em conciliação com o algoritmo *Random Forest* para atualizar dados de combustível em tempo real, melhorando significativamente as previsões de comportamento do fogo.

A fim de desenvolver modelos de mapeamentos de combustível, Mutlu et al. (2008) desenvolveram métodos que combinam dados LIDAR e imagens multiespectrais na região leste do Texas. Os resultados obtidos neste estudo demonstram que a fusão de dados LIDAR com imagens QuickBird melhorou significativamente a precisão do mapeamento de combustíveis. Não trabalhando diretamente com algoritmos de aprendizado de máquina, porém desenvolvendo modelos para mapeamento de combustível em extensas áreas florestais, Marino et al. (2016) utilizaram dados ALS (*Airborne Laser Scanner*) e imagens Landsat 8 OLI. A metodologia se mostrou eficaz para discriminar entre diferentes tipos de combustível e estrutura de vegetação.

Explorando o potencial das imagens Landsat 8 e Sentinel 2 para o mapeamento anual de biomassa de gramíneas em savanas, Berger et al. (2020) observaram que as informações de NDVI da estação chuvosa permitiram a criação de mapas confiáveis de biomassa para o Parque Nacional Kruger, na África do Sul. Lin e Ma (2020), baseando-se em dados geoespaciais integrados, desenvolveram um algoritmo para mapear a carga de combustível superficial em florestas montanhosas. Com a utilização de parâmetros biológicos e topográficos, o método realizou o mapeamento de carga de combustível, o qual demonstrou uma precisão razoável podendo ser uma ferramenta com potencial para a gestão de material combustível. Li et al. (2021a) fizeram a combinação de dados dos satélites Sentinel 1 e Sentinel 2 com as condições do local, como elevação e inclinação, para a estimativa de carga de combustível morto florestal na China. Utilizando o algoritmo *Random Forest*, o estudo demonstra que os dados de sensoriamento remoto são capazes de estimar a carga de combustível morto com boa precisão para todas as classes de combustível.

3.3 ESTIMATIVA DE UMIDADE DO COMBUSTÍVEL

Os estudos científicos destacam o uso de modelos de *machine learning* para prever a umidade do combustível vivo (LFMC) e morto (FMC), fatores cruciais na avaliação do risco de incêndios florestais. Cheruku et al. (2022) e Schreck et al. (2023) utilizaram dados de sensoriamento remoto de alta resolução e observações *in situ* para treinar modelos supervisionados, incluindo KNN, SVM, *Random Forest* e Redes Neurais. Cheruku et al. (2022) obtiveram uma precisão de até 76,1% ao prever incêndios com base na umidade do combustível, destacando a importância dos dados VIIRS na previsão precisa do FMC, melhorando significativamente a performance do uni-modelo.

No estudo de Huot et al. (2020), os autores demonstraram a eficácia dos modelos de *deep learning* para identificar áreas com alta probabilidade de incêndios, utilizando dados históricos e de sensoriamento remoto. O estudo de Schreck et al. (2023), que utilizou dados do VIIRS e variáveis de modelos de previsão numérica do tempo (NWP) para prever a umidade do combustível morto (FMC), demonstrou que as variáveis VIIRS são cruciais para a precisão dos modelos de aprendizado de máquina na previsão da umidade do combustível, mostrando uma melhoria substancial em comparação com outros métodos.

Apesar de trabalhar com estimativa de umidade do solo, o estudo de Adab et al. (2020) aplicou algoritmos de *machine learning*, incluindo *Random Forest* (RF), *Support Vector Machine* (SVM) e redes neurais artificiais (ANN), para estimar a umidade do solo superficial usando dados ópticos e térmicos do Landsat 8. O algoritmo RF foi o responsável pela maior eficiência do uso combinado de reflectância da superfície e dados geoespaciais auxiliares. Utilizando índices de vegetação extraídos de imagens MODIS, Li et al. (2020) aplicaram métodos de *machine learning*, como *Extreme Learning Machine* (ELM), *Gradient Boosting Decision Tree* (GBDT) e *Extreme Gradient Boosting* (XGBoost), para estimativa da umidade do combustível. McCandless, Kosovic e Petzke (2020) desenvolveram conjuntos de dados de umidade do combustível em alta resolução para serem assimilados em sistemas de previsão de incêndios florestais. Utilizou-se algoritmos de *machine learning*, incluindo o *Random Forest* e redes neurais artificiais, para estimativa da umidade do combustível com base em imagens de satélite e dados meteorológicos de superfície, melhorando a precisão das previsões de propagação de incêndios florestais.

Utilizando *machine learning* e dados de sensoriamento remoto, Kosovic et al. (2020) estimaram o conteúdo de umidade do combustível, combinando observações de satélite e de superfície, juntamente com saídas do Modelo Nacional de Água. Esta abordagem permitiu criar um conjunto de dados de alta resolução integrado ao Sistema de Previsão de Incêndios do Colorado. Wang et al. (2023), utilizando técnicas de *machine learning* para estimativa do conteúdo de umidade de combustível vivo, baseando-se em efeitos cumulativos e retardados de meteorologia e umidade do solo, alcançaram uma precisão considerável em diferentes tipos de coberturas vegetais apresentando acurácia específica. Xie et al. (2022) analisaram modelos de *deep learning* combinados, como LSTM, TCN e LSTM-TCN, para a recuperação do teor de umidade do material combustível vivo usando dados de sensoriamento remoto de múltiplas fontes. Esses modelos apresentaram maior precisão de recuperação comparados aos dados de uma única fonte.

Para prever a umidade de combustíveis vivos com três meses de antecedência nos EUA, Miller et al. (2023) investigaram o uso de redes neurais convolucionais temporais, demonstrando que o *deep learning* pode fornecer projeções precisas do conteúdo de umidade do combustível vivo (LFMC). Mandel et al. (2023) aplicaram uma metodologia que combina filtros de Kalman e redes neurais recorrentes para modelagem da umidade do combustível no sistema WRF-SFIRE, demonstrando

que a otimização de redes neurais pode aprimorar significativamente a precisão da modelagem.

3.4 COMPORTAMENTO E SEVERIDADE DE INCÊNDIOS FLORESTAIS

O conhecimento da severidade dos incêndios florestais é de fundamental importância para o entendimento do impacto ecológico e planejamento das estratégias de recuperação e manejo do material combustível. A combinação entre técnicas de *machine learning* com dados de sensoriamento remoto tem proporcionado avanços significativos nesse campo, proporcionando informações precisas e em tempo hábil sobre a severidade do fogo. Realizando mapeamento da severidade do fogo na Austrália, Gibson et al. (2020) utilizaram imagens de Sentinel 2 e o algoritmo *Random Forest*, demonstrando uma alta precisão na classificação das diferentes classes de severidade, com acurácia média superior a 85% para as classes de alta severidade. Utilizando bases de dados espectrais sintéticas e o algoritmo *Random Forest*, Montorio et al. (2020) mapearam a severidade dos incêndios na Sierra de Luna, Espanha. As categorias de severidade definidas demonstraram alta acurácia, com desempenho ligeiramente melhor ao utilizar informações de Sentinel 2 em comparação com Landsat 8.

O estudo de Simafranca et al. (2023) abordou técnicas de *machine learning* com o intuito de prever a severidade do fogo, desenvolvendo um modelo de *Super Learner* (SL) para a previsão da severidade dos incêndios por meio de dados de sensoriamento remoto pré-incêndio. Sim et al. (2020) utilizaram dados dos satélites Sentinel 1 e 2, juntamente com abordagens de *machine learning* para realizar o mapeamento da severidade dos incêndios florestais, onde o modelo *Random Forest* demonstrou maior desempenho. O estudo destacou a eficácia de técnicas de ML em conjunto com dados de alta resolução para a análise detalhada de incêndios florestais.

Aplicando o modelo de classificação XGBoost para previsão de incêndios florestais, Agrawal, Nelson e Low (2023), demonstraram que a abordagem pode ser utilizada para priorizar a alocação de recursos para proteger comunidades vulneráveis, mostrando a importância das técnicas avançadas de *machine learning* na previsão de incêndios com alta severidade. O trabalho de Zikiou et al. (2024) utilizaram *Support Vector Machines* (SVM) e redes neurais convolucionais (CNN) para mapeamento da severidade dos incêndios na Argélia, sendo que os modelos

alcançaram pontuações de precisão significativas, demonstrando a eficácia dessas técnicas para uma análise precisa de incêndios florestais em diferentes regiões geográficas.

Desenvolvendo um conjunto de dados de *machine learning*, Huot et al. (2022) apresentaram o objetivo de previsão da propagação de incêndios florestais, associando informações de sensoriamento remoto com diversas variáveis explicativas. A abordagem permitiu a criação de modelos preditivos de alta precisão para a propagação de incêndios, destacando o potencial das técnicas de ML para melhorar a gestão de incêndios florestais. Dahan et al. (2023), utilizando ferramentas de ML e sensoriamento remoto no *Google Earth Engine* a fim de analisar o impacto dos parâmetros climáticos e ambientais na propagação de incêndios, demonstraram a correlação entre variáveis como precipitação, temperatura e umidade do solo com a ocorrência de incêndios. Sharma et al. (2023) utilizaram de técnicas de ML, incluindo *Random Forest* e *Gradient Boosting*, para a modelagem preditiva da severidade do fogo considerando terrenos montanhosos de Victoria na Austrália. Tal estudo destacou a importância das influências topográficas na severidade dos incêndios e a eficácia das técnicas de ML para a análise preditiva.

Combinando dados de sensoriamento remoto e meteorológicos, Sharma, Aryal e Rajabifard (2022) trabalharam com a previsão da severidade dos incêndios na Austrália, destacando a importância da umidade e temperatura do solo, pressão do ar, temperatura do ar, vento vertical e umidade relativa, avaliando o desempenho preditivo, utilizando *Random Forest* (RF), *Fuzzy Forest* (FF), *Boosted Regression Tree* (BRT) e *Extreme Gradient Boosting* (XGBoost). Pham et al. (2022) focam na previsão de incêndios na Califórnia usando diversos modelos de *machine learning* e dados de sensoriamento remoto, alcançando altas precisões de predição de incêndios florestais.

3.5 TIPO DE MATERIAL COMBUSTÍVEL SUPERFICIAL

A caracterização e o mapeamento preciso dos diferentes tipos de material combustível são importantes para avaliação do perigo de propagação de incêndios florestais e implementação de estratégias de gestão eficazes. O estudo de Alipour et al. (2023) desenvolveu um modelo de identificação de combustível superficial em larga escala com a utilização de *deep learning* com intuito de extrair informações de

assinaturas multiespectrais, imagens de alta resolução e dados meteorológicos e de terreno. Para capturar incertezas de classificação e melhorar o desempenho da predição, este modelo utilizou um mecanismo de *dropout* de Monte Carlo.

O estudo de Aragonese et al. (2021) demonstrou o potencial do uso de *machine learning* combinado com dados de sensoriamento remoto para a criação de mapas detalhados de tipos de combustível. Pickell et al. (2021) desenvolveram o FuelNet, uma rede neural artificial utilizada para mapeamento e atualização de tipos de combustível por meio de imagens de satélite. O estudo aponta que as redes neurais têm potencial de serem usadas eficazmente para criar mapas de combustível com uma precisão razoável, recomendando melhorias futuras para a qualidade das amostras de treinamento e o *design* da arquitetura da rede.

A pesquisa de Carbone, Spiller e Laneve (2023) utilizou redes neurais convolucionais (CNN) para classificar tipologia do combustível em imagens Sentinel 2, atingindo altos níveis de precisão para classes principais como folhosas, coníferas, arbustos e gramíneas, gerando subclasses que foram usadas em mapas de biomassa e bioclimáticos. Mohammadpour et al. (2023) combinaram dados do Sentinel 1 e Sentinel 2 com um modelo digital de elevação e índices de vegetação para mapeamento de tipos de combustível em Portugal, utilizando a matriz de coocorrência de nível de cinza (*Gray-level co-occurrence matrix - GLCM*) e *Random Forest*, alcançando níveis de precisão significativos. Labenski et al. (2022) utilizaram técnicas de *machine learning* e dados de sensoriamento remoto para classificação de tipos de combustível superficial por meio de fotografias de florestas e séries temporais de satélites, mostrando resultados promissores para a melhoria da precisão no mapeamento de tipos de material combustível para previsões de comportamento do fogo.

3.6 PERIGO E RISCO DE INCÊNDIOS FLORESTAIS

A análise dos trabalhos mais recentes acerca da utilização de técnicas de *machine learning* e sensoriamento remoto para mapeamento do risco de incêndios florestais, demonstra diferentes abordagens promissoras. A previsão do comportamento do fogo e a avaliação do risco de incêndios florestais podem ser melhoradas através do uso de dados de umidade do solo e *machine learning*, como discutido por Sharma e Dhakal (2021). Estes autores demonstram como essas

técnicas podem melhorar a precisão na avaliação do perigo de incêndios. Seddouki et al. (2023) avaliaram a suscetibilidade a incêndios florestais no norte de Marrocos usando algoritmos de *machine learning* como XGBoost, *Random Forest* e SVM, integrados a um banco de dados GIS com diversos fatores causais. Os resultados indicaram que o XGBoost teve o melhor desempenho na previsão de incêndios. Bahadori et al. (2023) exploraram o uso de algoritmos de *deep learning*, como LSTM e RNN, para mapear suscetibilidade a incêndios utilizando imagens de satélite MODIS e Landsat 8. O estudo destaca que a utilização destes algoritmos demonstrou alta precisão na modelagem de suscetibilidade a incêndios, desempenhando importância para uma gestão eficiente de incêndios.

Utilizando *Random Forest* para analisar a suscetibilidade a incêndios no Arkansas, EUA, Saim e Aly (2022), destacando os fatores que contribuem para a densidade de incêndios, demonstraram a eficácia do sensoriamento remoto baseado em ML na previsão da suscetibilidade a incêndios em nível estadual. Ao avaliar o potencial de diferentes abordagens de *machine learning* para previsão espacial da suscetibilidade a incêndios florestais, Ghorbanzadeh et al. (2019) utilizaram um inventário de incêndios florestais gerado por meio de dados de GPS e dados do produto de anomalias térmicas do MODIS. Propondo um modelo *Ensemble* baseado em redes neurais profundas para mapear a suscetibilidade a incêndios, Bjânes, de la Fuente e Mena (2021) utilizaram dados de elevação, temperatura, velocidade do vento, precipitação, NDVI, entre outros, para treinar os modelos. O modelo Ensemble alcançou uma alta precisão na previsão de áreas suscetíveis a incêndios.

Revisando a detecção precoce de incêndios, Bouguettaya et al. (2022) utilizou veículos aéreos não tripulados (UAVs) e algoritmos de visão computacional baseados em *deep learning*. A abordagem se apresentou eficaz para detecção de incêndios em estágios iniciais, permitindo intervenções rápidas para prevenção da propagação descontrolada. Yoon e Voulgaris (2022) utilizaram técnicas de *machine learning* e dados de sensoriamento remoto para prever mapas de risco de incêndios com semanas de antecedência, abordando os desafios das observações de estado incompletas, ressaltando a importância de técnicas de estimativa dinâmica online e modelagem de séries temporais. Iban e Sekertekin (2022) aplicaram *machine learning* para mapeamento da suscetibilidade a incêndios nas províncias de Adana e Mersin, Turquia, utilizando dados de sensoriamento remoto e sistema de informações

geográficas (SIG), destacando a capacidade dos algoritmos aprendizados de máquina em analisar grandes volumes de dados para prever riscos de incêndio.

Utilizando algoritmos de *machine learning*, como redes neurais convolucionais (CNN), para detecção precoce de incêndios florestais, Mohamed, Hanae e Larbi (2020) observaram melhoras na previsão de incêndios e identificação de zonas de risco através de mapeamento em ambiente SIG. Tien Bui, Le e Hoang (2018) aplicaram métodos híbridos de *machine learning* com objetivo de prever espacialmente o perigo de incêndios em florestas tropicais, mostrando a eficácia dessas técnicas em prever áreas de alto risco com precisão significativa. Ma et al. (2020), por meio de técnicas avançadas de *machine learning*, desenvolveram um sistema de detecção em tempo real de riscos de incêndios causados por falhas de vegetação em linhas de energia. O sistema foi capaz de melhorar a capacidade de resposta a riscos de incêndio relacionados à infraestrutura. Le et al. (2021) apresentaram uma abordagem de computação neural profunda para previsão espacial de perigo de incêndios em regiões de clima tropical, integrando dados de sensoriamento remoto para aprimorar o nível de precisão das previsões.

4 CONSIDERAÇÕES FINAIS

A integração de técnicas de *machine learning* (ML), ou, aprendizado de máquina, com dados de sensoriamento remoto vem se mostrando uma abordagem eficaz para o mapeamento de variáveis associadas aos incêndios florestais. Esta combinação oferece uma considerável capacidade de analisar grandes volumes de dados, identificar padrões complexos e fornecer previsões precisas, importantes para a gestão e prevenção de incêndios florestais. Diversos estudos destacam os avanços significativos que esta combinação proporciona, contribuindo para uma gestão do fogo mais dinâmica e eficaz.

O sensoriamento remoto se apresenta como uma ferramenta de importância nas análises ambientais, permitindo a coleta de dados extensivos a cobertura do solo, dentre outros aspectos como a umidade do solo, a densidade da vegetação, a temperatura da superfície e outras condições atmosféricas, que são fundamentais, por exemplo, para analisar a probabilidade de ocorrência de incêndios de alta intensidade. Quando essas informações são combinadas com algoritmos de *machine learning*, é possível identificar padrões complexos e correlacionar variáveis ambientais com diferentes variáveis intrínsecas e relacionadas com o manejo dos incêndios florestais.

Diferentes estudos vêm demonstrando que algoritmos como *Random Forest*, *Support Vector Machine* (SVM) e Redes Neurais Artificiais (ANN) têm se mostrado eficazes na predição de diferentes variáveis relacionadas aos incêndios florestais. A aplicação desses modelos permite a criação de mapas de suscetibilidade a incêndios com níveis de precisão significativos, delimitações de área queimada de forma dinâmica, estimativas de carga e umidade do material combustível, dentre outras informações que são essenciais para a tomada de decisões estratégicas na prevenção e combate a incêndios.

A capacidade de realizar a previsão da ocorrência e a severidade do fogo com antecedência permite a alocação eficiente de recursos e o desenvolvimento de estratégias de mitigação mais eficazes. A combinação de técnicas de *deep learning*, como LSTM (*Long ShortTerm Memory*) e redes neurais convolucionais, com dados multiespectrais e provenientes de radar, também vem apresentando resultados promissores na detecção e mapeamento de áreas queimadas. Técnicas avançadas como essas, melhoram de forma significativa a precisão e a eficiência na detecção de incêndios, permitindo uma resposta mais rápida e eficaz.

Em conclusão, a integração de técnicas de *machine learning* e dados de sensoriamento remoto fornece uma abordagem robusta e eficiente para o mapeamento de diferentes variáveis relacionadas com os incêndios florestais, contribuindo significativamente para a gestão e mitigação de desastres ambientais. Essas tecnologias recentes continuam a evoluir de forma a ampliar cada vez mais seu portfólio de aplicações e seu potencial para aprimorar a precisão das previsões e a eficácia das estratégias de manejo do fogo. Ressalta-se, portanto, a necessidade contínua da pesquisa e desenvolvimento nesta área.

REFERÊNCIAS

- ADAB, H.; MORBIDELLI, R.; SALTALIPPI, C.; MORADIAN, M.; GHALHARI, G. A. F. Machine Learning to Estimate Surface Soil Moisture from Remote Sensing Data. **Water**, [S. l.], v. 12, n. 11, p. 3223, 2020. DOI: 10.3390/W12113223.
- AGRAWAL, N.; NELSON, P. V.; LOW, R. D. A Novel Approach for Predicting Large Wildfires Using Machine Learning towards Environmental Justice via Environmental Remote Sensing and Atmospheric Reanalysis Data across the United States. **Remote Sensing 2023**, [S. l.], v. 15, n. 23, p. 5501, 2023. DOI: 10.3390/RS15235501.
- ALIPOUR, M.; LA PUMA, I.; PICOTTE, J.; SHAMSAEI, K.; ROWELL, E.; WATTS, A.; KOSOVIC, B.; EBRAHIMIAN, H.; TACIROGLU, E. A Multimodal Data Fusion and Deep Learning Framework for Large-Scale Wildfire Surface Fuel Mapping. **Fire**, [S. l.], v. 6, n. 2, p. 36, 2023. DOI: 10.3390/FIRE6020036.
- ARAGONESES, E.; CHUVIECO, E.; STROPPIANA, D.; SMITH, A. M. S.; TINKHAM, W. T. Generation and Mapping of Fuel Types for Fire Risk Assessment. **Fire**, [S. l.], v. 4, n. 3, p. 59, 2021. DOI: 10.3390/FIRE4030059.
- ARAI, E.; SHIMABUKURO, Y. E.; DUTRA, A. C.; DUARTE, V. Detection and Analysis of Forest Degradation by Fire Using Landsat/Oli Images in Google Earth Engine. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], p. 1649–1652, 2019. DOI: 10.1109/IGARSS.2019.8899250.
- ARAÚJO, S. O.; PERES, R. S.; RAMALHO, J. C.; LIDON, F.; BARATA, J. Machine Learning Applications in Agriculture: Current Trends, Challenges, and Future Perspectives. **Agronomy**, [S. l.], v. 13, n. 12, p. 2976, 2023. DOI: 10.3390/AGRONOMY13122976.
- 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: 10.3390/F14071325.
- BAI, Y.; ZHANG, S.; BHATTARAI, N.; MALLICK, K.; LIU, Qi; T., L.; IM, J.; GUO, L.; ZHANG, J. On the use of machine learning based ensemble approaches to improve evapotranspiration estimates from croplands across a wide environmental gradient. **Agricultural and Forest Meteorology**, [S. l.], v. 298–299, p. 108308, 2021. DOI: 10.1016/J.AGRFORMET.2020.108308.
- BELENGUER-PLOMER, M. A.; TANASE, M. A.; CHUVIECO, E.; BOVOLO, F. CNN-based burned area mapping using radar and optical data. **Remote Sensing of Environment**, [S. l.], v. 260, p. 112468, 2021. DOI: 10.1016/J.RSE.2021.112468.
- BERGER, C.; LUX, H.; URBAN, M.; SCHMULLIUS, C.; BAADE, J.; THIEL, C.; WIGLEY-COETSEE, C.; SMIT, I. Annual Grass Biomass Mapping with Landsat-8 and Sentinel-2 Data over Kruger National Park, South Africa. **International**

Geoscience and Remote Sensing Symposium (IGARSS), [S. I.], p. 4323–4326, 2020. DOI: 10.1109/IGARSS39084.2020.9324413.

BJÄNES, A.; DE LA FUENTE, R.; MENA, P. A deep learning ensemble model for wildfire susceptibility mapping. **Ecological Informatics**, [S. I.], v. 65, p. 101397, 2021. DOI: 10.1016/J.ECOINF.2021.101397.

BOUGUETTAYA, A.; ZARZOUR, H.; TABERKIT, A. M.; KECHIDA, A. A review on early wildfire detection from unmanned aerial vehicles using deep learning-based computer vision algorithms. **Signal Processing**, [S. I.], v. 190, p. 108309, 2022. DOI: 10.1016/J.SIGPRO.2021.108309.

CARBONE, A.; SPILLER, D.; LANEVE, G. Fuel Type Mapping Using a CNN-Based Remote Sensing Approach: A Case Study in Sardinia. **Fire**, [S. I.], v. 6, n. 10, p. 395, 2023. DOI: 10.3390/FIRE6100395.

CHEN, S.; WOODCOCK, C. E.; BULLOCK, E. L.; ARÉVALO, P.; TORCHINAVA, P.; PENG, S.; OLOFSSON, P. Monitoring temperate forest degradation on Google Earth Engine using Landsat time series analysis. **Remote Sensing of Environment**, [S. I.], v. 265, p. 112648, 2021. DOI: 10.1016/J.RSE.2021.112648.

CHERUKU, R.; KOHLI, A.; KODALI, P.; KAVATI, I.; SURESHBABU, E. Predicting Wildfire using Live Fuel Moisture Content with Machine Learning. **IEEE 19th India Council International Conference**, [S. I.], 2022. DOI: 10.1109/INDICON56171.2022.10039960.

DAHAN, K. S.; KASEI, R. A.; HUSSEINI, R.; SAID, M. Y.; RAHMAN, M. M. Towards understanding the environmental and climatic changes and its contribution to the spread of wildfires in Ghana using remote sensing tools and machine learning (Google Earth Engine). **International Journal of Digital Earth**, [S. I.], v. 16, n. 1, p. 1300–1331, 2023. DOI: 10.1080/17538947.2023.2197263.

DE BEM, P. P.; DE CARVALHO, O. A.; GUIMARÃES, R. F.; GOMES, R. A. T. Change Detection of Deforestation in the Brazilian Amazon Using Landsat Data and Convolutional Neural Networks. **Remote Sensing**, [S. I.], v. 12, n. 6, p. 901, 2020. DOI: 10.3390/RS12060901.

DECASTRO, A. L.; JULIANO, T. W.; KOSOVIĆ, B.; EBRAHIMIAN, H.; BALCH, J. K. A. Computationally Efficient Method for Updating Fuel Inputs for Wildfire Behavior Models Using Sentinel Imagery and Random Forest Classification. **Remote Sensing**, [S. I.], v. 14, n. 6, p. 1447, 2022. DOI: 10.3390/RS14061447.

D'ESTE, M.; ELIA, M.; GIANNICO, V.; SPANO, G.; LAFORTEZZA, R.; SANESI, G. Machine Learning Techniques for Fine Dead Fuel Load Estimation Using Multi-Source Remote Sensing Data. **Remote Sensing**, [S. I.], v. 13, n. 9, p. 1658, 2021. DOI: 10.3390/RS13091658.

GHALI, R.; AKHLOUFI, M. A. Deep Learning Approaches for Wildland Fires Using Satellite Remote Sensing Data: Detection, Mapping, and Prediction. **Fire**, [S. I.], v. 6, n. 5, p. 192, 2023. DOI: 10.3390/FIRE6050192.

GHORBANZADEH, O.; KAMRAN, K. V.; BLASCHKE, T.; ARYAL, J.; NABOUREH, A.; EINALI, J.; BIAN, J. Spatial Prediction of Wildfire Susceptibility Using Field Survey GPS Data and Machine Learning Approaches. **Fire**, [S. l.], v. 2, n. 3, p. 43, 2019. DOI: 10.3390/FIRE2030043.

GHOSH, S. M.; BEHERA, M. D. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. **Applied Geography**, [S. l.], v. 96, p. 29–40, 2018. DOI: 10.1016/J.APGEOG.2018.05.011.

GIBSON, R.; DANAHER, T.; HEHIR, W.; COLLINS, L. A remote sensing approach to mapping fire severity in south-eastern Australia using sentinel 2 and random forest. **Remote Sensing of Environment**, [S. l.], v. 240, p. 111702, 2020. DOI: 10.1016/J.RSE.2020.111702.

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: 10.1016/J.RSE.2017.06.031.

HAN, K.; WANG, Y. A review of artificial neural network techniques for environmental issues prediction. **Journal of Thermal Analysis and Calorimetry**, [S. l.], v. 145, n. 4, p. 2191–2207, 2021. DOI: 10.1007/S10973-021-10748-9.

HU, X.; BAN, Y.; NASCETTI, A. Uni-Temporal Multispectral Imagery for Burned Area Mapping with Deep Learning. **Remote Sensing 2021**, [S. l.], v. 13, n. 8, p. 1509, 2021. DOI: 10.3390/RS13081509.

HUOT, F.; HU, R. L.; GOYAL, N.; SANKAR, T.; IHME, M.; CHEN, Yi F. Next Day Wildfire Spread: A Machine Learning Dataset to Predict Wildfire Spreading From Remote-Sensing Data. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 60, 2022. DOI: 10.1109/TGRS.2022.3192974.

HUOT, F.; HU, R. L.; IHME, M.; WANG, Q.; BURGE, J.; LU, T.; HICKEY, J.; CHEN, Y.; ANDERSON, J. Deep Learning Models for Predicting Wildfires from Historical Remote-Sensing Data. **arXiv**, [S. l.], v. 3, 2020. DOI: 10.48550/arXiv.2010.07445.

IBAN, M. C.; SEKERTEKIN, A. Machine learning based wildfire susceptibility mapping using remotely sensed fire data and GIS: A case study of Adana and Mersin provinces, Turkey. **Ecological Informatics**, [S. l.], v. 69, p. 101647, 2022. DOI: 10.1016/J.ECOINF.2022.101647.

JALAL, D.; EZZEDINE, T. Performance analysis of machine learning algorithms for water quality monitoring system. **2019 International Conference on Internet of Things, Embedded Systems and Communications**, [S. l.], p. 86–89, 2019. DOI: 10.1109/IINTEC48298.2019.9112096.

KALANTAR, B.; UEDA, N.; IDREES, M. O.; JANIZADEH, S.; AHMADI, K.; SHABANI, Farzin. 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: 10.3390/RS12223682.

KANEVSKI, M.; PARKIN, R.; POZDNUKHOV, A.; TIMONIN, V.; MAIGNAN, M.; DEMYANOV, V.; CANU, S. Environmental data mining and modeling based on machine learning algorithms and geostatistics. **Environmental Modelling & Software**, [S. l.], v. 19, n. 9, p. 845–855, 2004. DOI: 10.1016/J.ENVSOFT.2003.03.004.

KOSOVIC, B.; JIMENEZ, P.; MCCANDLESS, T.; PETZKE, Bill; MASSIE, S.; SIEMSE-ANDERSON, A.; DECASTRO, A.; MUNOZ-ESPARZA, D.; HAUPT, S. E. Estimation of Fuel Moisture Content by Integrating Surface and Satellite Observations Using Machine Learning. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], p. 3626–3628, 2020. DOI: 10.1109/IGARSS39084.2020.9323134.

LABENSKI, P.; EWALD, M.; SCHMIDTLEIN, S.; FASSNACHT, F. E. Classifying surface fuel types based on forest stand photographs and satellite time series using deep learning. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 109, p. 102799, 2022. DOI: 10.1016/J.JAG.2022.102799.

LE, H. V.; HOANG, D.A.; TRAN, C.T.; NGUYEN, P.Q.; TRAN, V.H.T.; HOANG, N.D.; AMIRI, M.; NGO, T.P.T.; NHU, H.V.; VAN HOANG, T.; TIEN BUI, D. A new approach of deep neural computing for spatial prediction of wildfire danger at tropical climate areas. **Ecological Informatics**, [S. l.], v. 63, p. 101300, 2021. DOI: 10.1016/J.ECOINF.2021.101300.

LI, F.; LI, Y.; ZHANG, C.; CHENG, Y.; LI, Y.; HE, L. A Fuel Moisture Content Monitoring Methodology Based on Optical Remote Sensing. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], p. 4634–4637, 2020. DOI: 10.1109/IGARSS39084.2020.9323353.

LI, Y.; HE, B.; KONG, P.; XU, H.; ZHANG, Q.; QUAN, X. Estimation of Forest Surface Dead Fuel Loads Based on Multi-Source Remote Sensing Data. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], v. 2021- July, p. 6893–6896, 2021. DOI: 10.1109/IGARSS47720.2021.9553105.

LI, Y.; LAI, G.; QUAN, X. A Physical Method for Crown Foliage Fuel Load Retrieval from Landsat Data: Toward Crown Fire Danger Assessment. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], v. 2022- July, p. 7855–7858, 2022. DOI: 10.1109/IGARSS46834.2022.9883232.

LIN, C.; MA, S. E. Mapping Surface Fuel Loadings of Forests Using Stratified Random Sampling and Geostatistical Analysis Derived Data. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], p. 4638–4640, 2020. DOI: 10.1109/IGARSS39084.2020.9324499.

MA, J.; CHENG, J. C. P.; JIANG, F.; GAN, V. J. L.; WANG, M.; ZHAI, C. Real-time detection of wildfire risk caused by powerline vegetation faults using advanced machine learning techniques. **Advanced Engineering Informatics**, [S. l.], v. 44, p. 101070, 2020. DOI: 10.1016/J.AEI.2020.101070.

MANDEL, J.; HIRSCHI, J.; KOCHANSKI, A. K.; FARGUELL, A.; HALEY, J.; MALLIA, D. V.; SHADDY, B.; OBERAI, A. A.; HILBURN, K. A. Building a Fuel Moisture Model for the Coupled Fire-Atmosphere Model WRF-SFIRE from Data: From Kalman Filters

to Recurrent Neural Networks. **arXiv**, [S. l.], v. 1, n. arXiv:2301.05427, p. 1–4, 2023. DOI: 10.48550/arXiv.2301.05427.

MARINO, E.; RANZ, P.; TOMÉ, J. L.; NORIEGA, M. A.; ESTEBAN, J.; MADRIGAL, J. Generation of high-resolution fuel model maps from discrete airborne laser scanner and Landsat-8 OLI: A low-cost and highly updated methodology for large areas. **Remote Sensing of Environment**, [S. l.], v. 187, p. 267–280, 2016. DOI: 10.1016/J.RSE.2016.10.020.

MCCANDLESS, T. C.; KOSOVIC, B.; PETZKE, W. Enhancing wildfire spread modelling by building a gridded fuel moisture content product with machine learning. **Machine Learning: Science and Technology**, [S. l.], v. 1, n. 3, p. 035010, 2020. DOI: 10.1088/2632-2153/ABA480.

MILLER, L.; ZHU, L.; YEBRA, M.; RÜDIGER, C.; WEBB, G. I. Projecting live fuel moisture content via deep learning. **International Journal of Wildland Fire**, [S. l.], v. 32, n. 5, p. 709–727, 2023. DOI: 10.1071/WF22188.

MOHAJANE, M.; COSTACHE, R.; KARIMI, F.; BAO PHAM, Q.; ESSAHLAOUI, A.; NGUYEN, H.; LANEVE, G.; OUDIJA, F. Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. **Ecological Indicators**, [S. l.], v. 129, p. 107869, 2021. DOI: 10.1016/J.ECOLIND.2021.107869.

MOHAMMADPOUR, P.; VIEGAS, D. X.; CHUVIECO, E.; PEREIRA, A.; MANTAS, V. Vegetation Fuel Type Classification Using Optimised Synergy of Sentinel Data and Texture Feature. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], v. 2023- July, p. 3098–3101, 2023. DOI: 10.1109/IGARSS52108.2023.10281659.

MOHAMMED, Z.; HANAE, C.; LARBI, S. Comparative study on machine learning algorithms for early fire forest detection system using geodata. **International Journal of Electrical and Computer Engineering (IJECE)**, [S. l.], v. 10, n. 5, p. 5507–5513, 2020. DOI: 10.11591/IJECE.V10I5.PP5507-5513.

MONTORIO, R.; PÉREZ-CABELLO, F.; BORINI ALVES, D.; GARCÍA-MARTÍN, A. Unitemporal approach to fire severity mapping using multispectral synthetic databases and Random Forests. **Remote Sensing of Environment**, [S. l.], v. 249, p. 112025, 2020. DOI: 10.1016/J.RSE.2020.112025.

MUTLU, M.; POPESCU, S. C.; STRIPLING, C.; SPENCER, T. Mapping surface fuel models using lidar and multispectral data fusion for fire behavior. **Remote Sensing of Environment**, [S. l.], v. 112, n. 1, p. 274–285, 2008. DOI: 10.1016/J.RSE.2007.05.005.

NEGRI, R. G.; LUZ, A. E. O.; FRERY, A. C.; CASACA, W. Mapping Burned Areas with Multitemporal–Multispectral Data and Probabilistic Unsupervised Learning. **Remote Sensing**, [S. l.], v. 14, n. 21, p. 5413, 2022. DOI: 10.3390/RS14215413.

NGUYEN, T. D.; KAPPAS, M. Estimating the Aboveground Biomass of an Evergreen Broadleaf Forest in Xuan Lien Nature Reserve, Thanh Hoa, Vietnam, Using SPOT-6

Data and the Random Forest Algorithm. **International Journal of Forestry Research**, [S. l.], v. 2020, p. 1–13, 2020. DOI: 10.1155/2020/4216160.

PANDIT, S.; TSUYUKI, S.; DUBE, T. Estimating above-ground biomass in sub-tropical buffer zone community forests, Nepal, using Sentinel 2 data. **Remote Sensing**, [S. l.], v. 10, n. 4, 2018. DOI: 10.3390/rs10040601.

PHAM, K.; WARD, D.; RUBIO, S.; SHIN, D.; ZLOTIKMAN, L.; RAMIREZ, S.; POPLAWSKI, T.; JIANG, X. California Wildfire Prediction using Machine Learning. **21st IEEE International Conference on Machine Learning and Applications, ICMLA 2022**, [S. l.], p. 525–530, 2022. DOI: 10.1109/ICMLA55696.2022.00086.

PICKELL, P. D.; CHAVARDÈS, R. D.; LI, S.; DANIELS, L. D. FuelNet: An Artificial Neural Network for Learning and Updating Fuel Types for Fire Research. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 59, n. 9, p. 7340–7352, 2021. DOI: 10.1109/TGRS.2020.3037160.

PINTO, M. M.; LIBONATI, R.; TRIGO, R. M.; TRIGO, I. F.; DACAMARA, C. C. A deep learning approach for mapping and dating burned areas using temporal sequences of satellite images. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 160, p. 260–274, 2020. DOI: 10.1016/J.ISPRSJPRS.2019.12.014.

PRABOWO, Y.; SAKTI, A.D.; PRADONO, K.A.; AMRIYAH, Q.; RASYIDY, F.H.; BENGKULAH, I.; ULFA, K.; CANDRA, D.S.; IMDAD, M.T.; ALI, S. Deep learning dataset for estimating burned areas: case study, Indonesia. **Data**, [S. l.], v. 7, n. 6, p. 78, 2022. DOI: 10.3390/DATA7060078.

REIS, R.; DATIA, N.; PATO, M. A primer on understanding Google Earth Engine APIs. **Academic Journal of Electronics Telecommunications and Computers**, [S. l.], v. 6, n. 1, p. 4, 2020. DOI: 10.34629/IPL.ISEL.I-ETC.81.

SAIM, A. Al; ALY, M. H. Machine Learning for Modeling wildfire susceptibility at the state level: an example from Arkansas, USA. **Geographies**, [S. l.], v. 2, n. 1, p. 31–47, 2022. DOI: 10.3390/GEOGRAPHIES2010004.

SANTOS, S. M. B.; DUVERGER, S. G.; BENTO-GONÇALVES, A.; FRANCA-ROCHA, W.; VIEIRA, A.; TEIXEIRA, G. Remote sensing applications for mapping large wildfires based on machine learning and time series in northwestern Portugal. **Fire**, [S. l.], v. 6, n. 2, p. 43, 2023. DOI: 10.3390/FIRE6020043.

SCHRECK, J. S.; PETZKE, W.; JIMÉNEZ, P. A.; BRUMMET, T.; KNIEVEL, J. C.; JAMES, E.; KOSOVIĆ, B.; GAGNE, D. J. Machine learning and VIIRS satellite retrievals for skillful fuel moisture content monitoring in wildfire management. **Remote Sensing**, [S. l.], v. 15, n. 13, p. 3372, 2023. DOI: 10.3390/RS15133372.

SEDDOUKI, M.; BENAYAD, M.; AAMIR, Z.; TAHIRI, M.; MAANAN, M.; RHINANE, H. Using machine learning coupled with remote sensing for forest fire susceptibility mapping: case study tetouan province, northern Morocco. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, [S. l.], v. XLVIII-4-W6-2022, n. 4/W6-2022, p. 333–342, 2023. DOI: 10.5194/ISPRS-ARCHIVES-XLVIII-4-W6-2022-333-2023.

SHARMA, S. K.; ARYAL, J.; RAJABIFARD, A. Remote sensing and meteorological data fusion in predicting bushfire severity: a case study from Victoria, Australia. **Remote Sensing**, [S. l.], v. 14, n. 7, p. 1645, 2022. DOI: 10.3390/RS14071645.

SHARMA, S. K.; ARYAL, J.; SHAO, Q.; RAJABIFARD, A. Characterizing topographic influences of bushfire severity using machine learning models: a case study in a Hilly terrain of Victoria, Australia. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.], v. 16, p. 2791–2807, 2023. DOI: 10.1109/JSTARS.2023.3249643.

SHARMA, S.; DHAKAL, K. Boots on the ground and eyes in the sky: a perspective on estimating fire danger from soil moisture content. **Fire**, [S. l.], v. 4, n. 3, p. 45, 2021. DOI: 10.3390/FIRE4030045.

SHERSTJUK, V.; ZHARIKOVA, M.; SOKOL, I. Forest fire-fighting monitoring system based on UAV team and remote sensing. **IEEE 38th International Conference on Electronics and Nanotechnology**, [S. l.], p. 663–668, 2018. DOI: 10.1109/ELNANO.2018.8477527.

SILVA-CARDOZA, A. I.; VEGA-NIEVA, D. J.; BRISEÑO-REYES, J.; BRIONES-HERRERA, C. I.; LÓPEZ-SERRANO, P. M.; CORRAL-RIVAS, J. J.; PARKS, S. A.; HOLSINGER, L. M. Evaluating a new relative phenological correction and the effect of sentinel-based earth engine compositing approaches to map fire severity and burned area. **Remote Sensing**, [S. l.], v. 14, n. 13, p. 3122, 2022. DOI: 10.3390/RS14133122/S1.

SIM, S.; KIM, W.; LEE, J.; KANG, Y.; IM, J.; KWON, C.; KIM, S. Wildfire severity mapping using sentinel satellite data based on machine learning approaches. **Korean Journal of Remote Sensing**, [S. l.], v. 36, n. 5_3, p. 1109–1123, 2020. DOI: 10.7780/KJRS.2020.36.5.3.9.

SIMAFRANCA, N.; WILLOUGHBY, B.; O'NEIL, E.; FARR, S.; REICH, B. J.; GIERTYCH, N.; JOHNSON, M.; PASCOLINI-CAMPBELL, M. Modelling wildland fire burn severity in California using a spatial Super Learner approach. **Environmental and Ecological Statistics**, [S. l.], 2023. DOI: 10.1007/s10651-024-00601-1.

SINGH, C.; KARAN, S. K.; SARDAR, P.; SAMADDER, S. R. Remote sensing-based biomass estimation of dry deciduous tropical forest using machine learning and ensemble analysis. **Journal of Environmental Management**, [S. l.], v. 308, p. 114639, 2022. DOI: 10.1016/J.JENVMAN.2022.114639.

STROPPIANA, D.; BORDOGNA, G.; SALI, M.; BOSCHETTI, M.; SONA, G.; BRIVIO, P. A. A fully automatic, interpretable and adaptive machine learning approach to map burned area from remote sensing. **ISPRS International Journal of Geo-Information** **2021**, [S. l.], v. 10, n. 8, p. 546, 2021. DOI: 10.3390/IJGI10080546.

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: 10.1016/J.ISPRSJPRS.2020.04.001.

THAPA, B.; LOVELL, S.; WILSON, J. Remote sensing and machine learning applications for aboveground biomass estimation in agroforestry systems: a review. **Agroforestry Systems**, [S. l.], v. 97, n. 6, p. 1097–1111, 2023. DOI: 10.1007/S10457-023-00850-2/METRICS.

TIEN BUI, D.; LE, H. V.; HOANG, N. D. GIS-based spatial prediction of tropical forest fire danger using a new hybrid machine learning method. **Ecological Informatics**, [S. l.], v. 48, p. 104–116, 2018. DOI: 10.1016/J.ECOINF.2018.08.008.

VELIZAROVA, E.; NEDKOV, R.; AVETISYAN, D.; RADEVA, K.; STOYANOV, A.; GEORGIEV, N.; GIGOVA, I. Application of remote sensing techniques for monitoring of the climatic parameters in forest fire vulnerable regions in Bulgaria. **Seventh International Conference on Remote Sensing and Geoinformation of the Environment**, [S. l.], v. 11174, p. 451–462, 2019. DOI: 10.1117/12.2533656.

WANG, W.; CHEN, R.; LI, M.; FAN, C.; JIAO, M. Estimation of live fuel moisture content based on a machine learning approach. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], v. 2023- July, p. 3070–3073, 2023. DOI: 10.1109/IGARSS52108.2023.10283304.

XIE, J.; QI, T.; HU, W.; HUANG, H.; CHEN, B.; ZHANG, J. Retrieval of live fuel moisture content based on multi-source remote sensing data and ensemble deep learning model. **Remote Sensing**, [S. l.], v. 14, n. 17, p. 4378, 2022. DOI: 10.3390/RS14174378.

YANGLI-AO G.; MING L.; QINGYONG L.; RUISI H. Introduction of machine learning. **Applications of Machine Learning in Wireless Communications**, [S. l.], p. 1–65, 2019. DOI: 10.1049/PBTE081E_CH1.

YOON, H. J.; VOULGARIS, P. Multi-time predictions of wildfire grid map using remote sensing local data. **13th IEEE International Conference on Knowledge Graph**, [S. l.], p. 365–372, 2022. DOI: 10.1109/ICKG55886.2022.00053.

ZAYTAR, M. A.; EL AMRANI, C. Machine learning methods for air quality monitoring. **ACM International Conference Proceeding Series**, [S. l.], 2020. DOI: 10.1145/3386723.3387835.

ZHAO, Q.; YU, L.; LI, X.; PENG, D.; ZHANG, Y.; GONG, P. Progress and trends in the application of google earth and google earth engine. **Remote Sensing**, [S. l.], v. 13, n. 18, p. 3778, 2021. DOI: 10.3390/RS13183778/S1.

ZIKIOU, N.; RUSHMEIER, H.; CAPEL, M. I.; KANDAKJI, T.; RIOS, N.; LAHDIR, M. Remote sensing and machine learning for accurate fire severity mapping in northern Algeria. **Remote Sensing**, [S. l.], v. 16, n. 9, p. 1517, 2024. DOI: 10.3390/RS16091517.

CAPÍTULO 2 - RELAÇÕES ENTRE PRODUTOS DE LANDSAT 8 OLI E UMIDADE E CARGA DE MATERIAL COMBUSTÍVEL SUPERFICIAL EM AMBIENTE CAMPESTRE DE CERRADO

RESUMO

A aplicação de métodos sensoramento remoto para estimativas, classificação e caracterização do combustível superficial de maneira indireta se mostra como essencial para a obtenção de informações remotamente, com maior eficiência e custos reduzidos. O presente estudo teve como objetivo a avaliação das relações existentes entre os produtos de Landsat 8 OLI e a carga e umidade do combustível superficial em ambiente campestre de Cerrado. O trabalho foi conduzido na Estação Ecológica Serra Geral do Tocantins, no período de maio a setembro, onde foram coletadas 64 unidades de amostragens de dados, obedecendo-se um distanciamento entre as unidades de no mínimo 100 metros uma da outra. As obtenções dos valores dos *pixels* associados com as parcelas de campo foram feitas de uma janela de 3 x 3 *pixels*, no entorno do *pixel* de referência. Desta forma, foram extraídos os valores medianos dentre os *pixels* de cada poligonal de 3 x 3 *pixels* ligadas às parcelas de campo. Após a obtenção das informações das imagens de satélite correspondentes ao período de coleta dos dados *in loco*, e tabulação dos dados foram realizadas as análises de correlação linear de Pearson entre os dados de carga do combustível superficial e as variáveis independentes obtidas do processamento das imagens de satélite. As correlações entre as variáveis das análises de mistura espectral e carga e umidade do combustível foram superiores entre combustível herbáceo morto e fração solo de $r = -0,81$ (carga) e $r = -0,60$ (umidade). Entre a reflectância das bandas de Landsat 8 e carga combustível, as correlações superiores foram entre combustível herbáceo morto e a região do infravermelho próximo, com valores negativos de $r = -0,68$ (carga) e $r = -0,61$ (umidade), enquanto que as correlações entre índices de vegetação vs. carga e umidade do combustível, as relações superiores foram entre combustível herbáceo morto vs. os índices MSI ($r = 0,77$), NDII6 e GVMI ($r = -0,77$), considerando as correlações com a carga do combustível. Considerando a umidade do combustível, foram encontradas correlações negativas com os índices DER23 ($r = -0,57$) e MNDWI ($r = -0,56$) e positiva com o MSI ($r = 0,47$). As relações foram superiores entre a carga e umidade nas classes de combustíveis mortos, especialmente com a carga de combustível herbáceo morto.

Palavras-chave: carga do combustível; correlações lineares; imagens de satélite; processamento de imagens

CHAPTER 2 - RELATIONSHIPS BETWEEN LANDSAT 8 OLI PRODUCTS AND HUMIDITY AND SURFACE FUEL LOAD IN CERRADO GRASSLAND ENVIRONMENT

ABSTRACT

Implementing remote sensing methods to indirectly estimate, classify, and characterize surface fuel is essential for obtaining information remotely, with greater efficiency and reduced costs. The present study aims to evaluate the relationships between Landsat 8 OLI products and surface fuel load and humidity in a rural Cerrado environment. The work was conducted at the Serra Geral do Tocantins Ecological Station, from May to September, where 64 data sampling units were collected, observing a distance between the units of at least 100 meters from each other. The pixel values associated with the field plots were obtained from a 3 x 3-pixel window surrounding the reference pixel. This way, the median values were extracted among the pixels of each 3 x 3 pixel polygon linked to the field plots. After obtaining information from satellite images from the on-site data collection period and tabulating the data, Pearson's linear correlation analyses were carried out between the surface fuel load data and the independent variables obtained from the processing of satellite images. The correlations between the variables of the spectral mixture analysis and fuel load and moisture were higher between dead herbaceous fuel and soil fraction of $r = -0.81$ (load) and $r = -0.60$ (moisture). Between the reflectance of the Landsat 8 bands and fuel load, the highest correlations were between dead herbaceous fuel and the near-infrared region, with negative values of $r = -0.68$ (load) and $r = -0.61$ (moisture), while the correlations between vegetation indices vs. fuel load and moisture, the superior relationships were between dead herbaceous fuel vs. the MSI ($r = 0.77$), NDII6 and GVM1 ($r = -0.77$) indices, considering the correlations with the fuel load. Considering fuel moisture, negative correlations were found with the DER23 ($r = -0.57$) and MNDWI ($r = -0.56$) indices and positive correlations with the MSI ($r = 0.47$). The relationships between load and moisture were higher in the dead fuel classes, especially with the dead herbaceous fuel load.

Keywords: fuel load; linear correlations; satellite images; image processing

1 INTRODUÇÃO

Os incêndios florestais são capazes de causar consideráveis danos às florestas e às comunidades vizinhas porque podem se propagar rapidamente em áreas extensas (MOLLICONE; EVA; ACHARD, 2006) e atuam como o fator de distúrbio de considerável importância nos ecossistemas, que podem levar a mudanças mais drásticas na estrutura e função da vegetação (GONZÁLEZ-PÉREZ et al., 2004). No contexto dos incêndios florestais, o material combustível apresenta-se como um dos principais fatores a serem considerados para o manejo do fogo e o único que é passível de controle através da ação do homem (ROTHERMEL, 1972).

A descrição e a quantificação do material inflamável são essenciais para entender o comportamento do fogo de maneira adequada. Essas informações são relevantes para o manejo do fogo, a execução de queimas controladas, as atividades de combate a incêndios e a avaliação do perigo de incêndios florestais. Além disso, esses dados permitem a criação de modelos para determinar o carbono (GOULD; LACHLAN MCCAW; PHILLIP CHENEY, 2011). A determinação de características do combustível por meio de coletas de campo, no entanto, é de elevada complexidade, demandando de considerável tempo operacional e gastos em campanhas de campo para que se atinjam tamanhos amostrais representativos de uma determinada população (DUFF; BELL; YORK, 2012; RICCARDI et al., 2007).

Assim, métodos indiretos, como a modelagem biofísica, podem ser empregados para estimar parâmetros que são difíceis de obter diretamente (KEANE; BURGAN; VAN WAGTENDONK, 2001). Nesse contexto, Duff, Bell e York (2012) destacam que, dado que o material combustível é resultado das propriedades da vegetação de um local específico, é inegável que modelos biofísicos podem ser utilizados para prever atributos quantitativos do combustível. As determinações indiretas do material combustível superficial através de modelagens matemáticas em ambiente de Cerrado, entretanto, são pouco realizadas e cientificamente pouco validadas em virtude dos escassos estudos que são conduzidos no bioma.

A utilização de técnicas de sensoriamento remoto para estimativas, classificação e determinação de atributos do material combustível superficial de forma indireta, surge como crucial para a obtenção de forma remota, com maior agilidade e menores custos. Técnicas de sensoriamento remoto são importantes para estimar diversas características do material combustível e estão sendo cada vez mais

investigadas e aprimoradas. De acordo com Roberts et al. (2003), entre as várias técnicas de sensoriamento remoto, os produtos obtidos podem ajudar na avaliação do perigo de incêndios florestais, incluindo: (i) medições indiretas da umidade do combustível vivo; (ii) medições da biomassa herbácea viva; (iii) avaliações da condição do combustível; e (iv) classificações do tipo de combustível.

Dentre os trabalhos realizados utilizando produtos de sensoriamento remoto na determinação das relações com diferentes atributos de combustíveis superficiais, Franke et al. (2018) estudaram as relações entre produtos provenientes de análise de mistura espectral e o combustível superficial em ambiente campestre de Cerrado, sendo um dos poucos que trabalharam com a temática neste bioma. Existem ainda trabalhos que utilizam os valores de reflectância das imagens de satélite (e.g. CASAS et al., 2014; HADI et al., 2016; MERRILL et al., 1993; ZHANG et al., 2018), e com o cálculo de índices de vegetação e suas relações com características da biomassa (e.g. DANSON; BOWYER, 2004; GAO et al., 2020; GARCÍA et al., 2020; ZORMPAS et al., 2017).

Chuvieco et al. (2002) trabalharam com utilização da reflectância e índices de vegetação provenientes de sensor *Landsat Thematic Mapper* (TM) para a determinação do conteúdo de umidade do combustível, enquanto Peterson; Roberts e Dennison (2008) utilizaram dados de MODIS para cálculos de índices de vegetação para estabelecer relações empíricas com o conteúdo de umidade do combustível vivo. Enquanto Rodriguez-Jimenez et al. (2023) realizaram a modelagem de umidade de combustível vivo através de índices espectrais de imagens de Sentinel 2 e dados meteorológicos e Rao et al. (2020) utilizaram dados de radar (Sentinel 1) e dados ópticos de Landsat 8 OLI para mapeamento do conteúdo de umidade do combustível vivo.

Apesar da considerável quantidade de estudos utilizando técnicas e produtos de sensoriamento remoto para estimativas e mapeamentos de características do combustível superficial, pesquisas científicas com combustíveis do bioma Cerrado são escassas. Ressalta-se a necessidade do entendimento das relações entre as respostas espectrais provenientes de imagens de satélite e as características do material combustível de Cerrado, tendo em vista a heterogeneidade e complexidade de obtenção de informações do material combustível neste bioma.

1.1 HIPÓTESES

O presente estudo foi baseado nas seguintes hipóteses:

- (i) Existe relação significativa entre os valores de fração obtidos pela análise de mistura espectral (AMS) da vegetação verde, de vegetação seca e de solo com as variáveis de carga e umidade do material combustível superficial;
- (ii) Existe relação significativa entre os valores de reflectância e índices de vegetação com as variáveis de carga e umidade do material combustível superficial.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Avaliar as possíveis relações existentes entre os dados provenientes do sensor Landsat 8 OLI e a carga e umidade do material combustível superficial durante a estação seca em ambiente campestre de Cerrado avaliando a viabilidade da estimativa de carga e umidade do combustível.

2.2 OBJETIVOS ESPECÍFICOS

- (i) Avaliar a metodologia da análise de mistura espectral para obtenção de informação quantitativa de mapas das condições fisiológicas do combustível (seco ou verde);
- (ii) Estabelecer análises de correlação linear múltiplas e analisar as relações existentes entre carga e umidade de combustível superficial com os valores-fração obtidos da análise de mistura espectral;
- (iii) Avaliar as correlações existentes entre carga e umidade do combustível superficial com a reflectância e índices de vegetação provenientes do sensor Landsat 8 OLI.

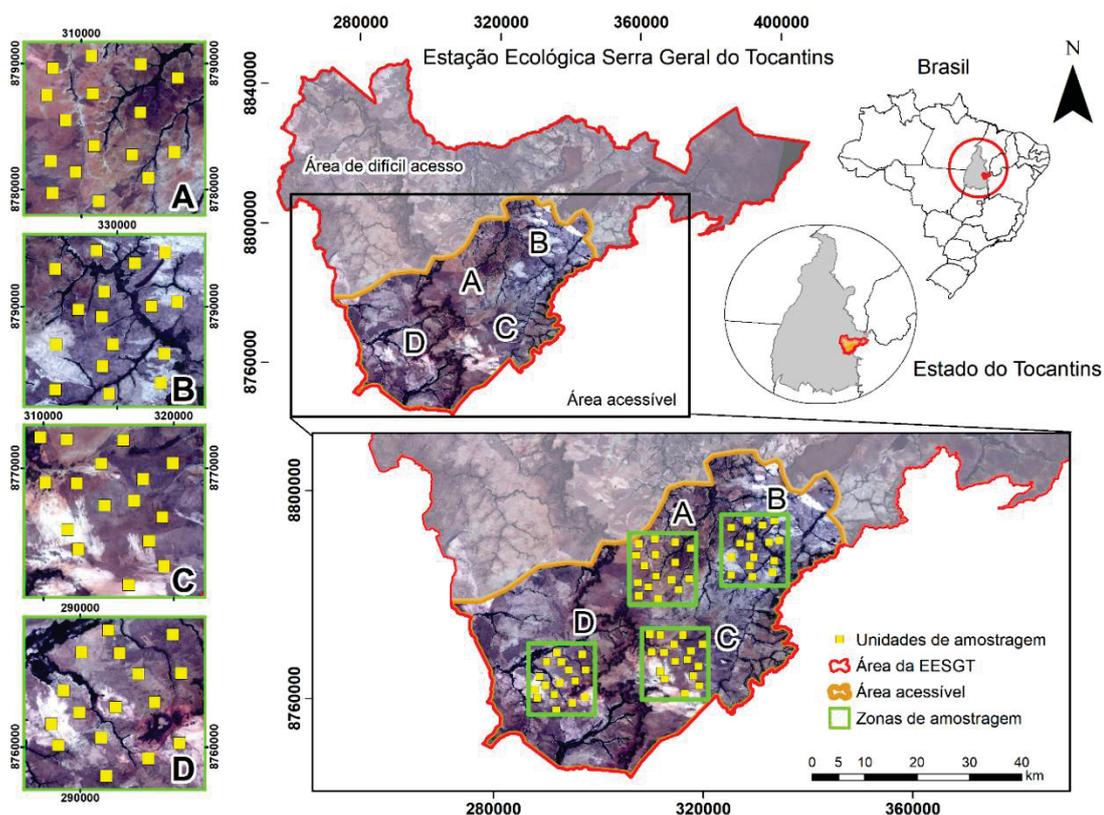
3 MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

As coletas de campo foram realizadas na porção centro-sul da Estação Ecológica Serra Geral do Tocantins (EESGT), uma unidade de conservação de proteção integral, situada no bioma Cerrado, na região do Jalapão que possui uma área de 716.306 ha. A EESGT abrange cinco diferentes municípios, sendo os municípios de Almas, Mateiros, Ponte Alta e Rio da Conceição, pertencentes ao estado do Tocantins e o município de Formosa do Rio Preto pertencente ao estado da Bahia (Figura 2).

Segundo a classificação climática de Köppen, o clima da região é do tipo Aw (clima tropical de savana) cuja precipitação anual varia de 1.400 a 1.500 mm (SEPLAN, 2012), sendo superior à evapotranspiração potencial anual. Na região, o verão é chuvoso, ocorrendo entre os meses de outubro a abril, e o inverno é seco ocorrendo entre os meses de maio e setembro (ICMBIO, 2014).

FIGURA 2 - ÁREA DE ESTUDO E DISTRIBUIÇÃO DAS PARCELAS DE CAMPO



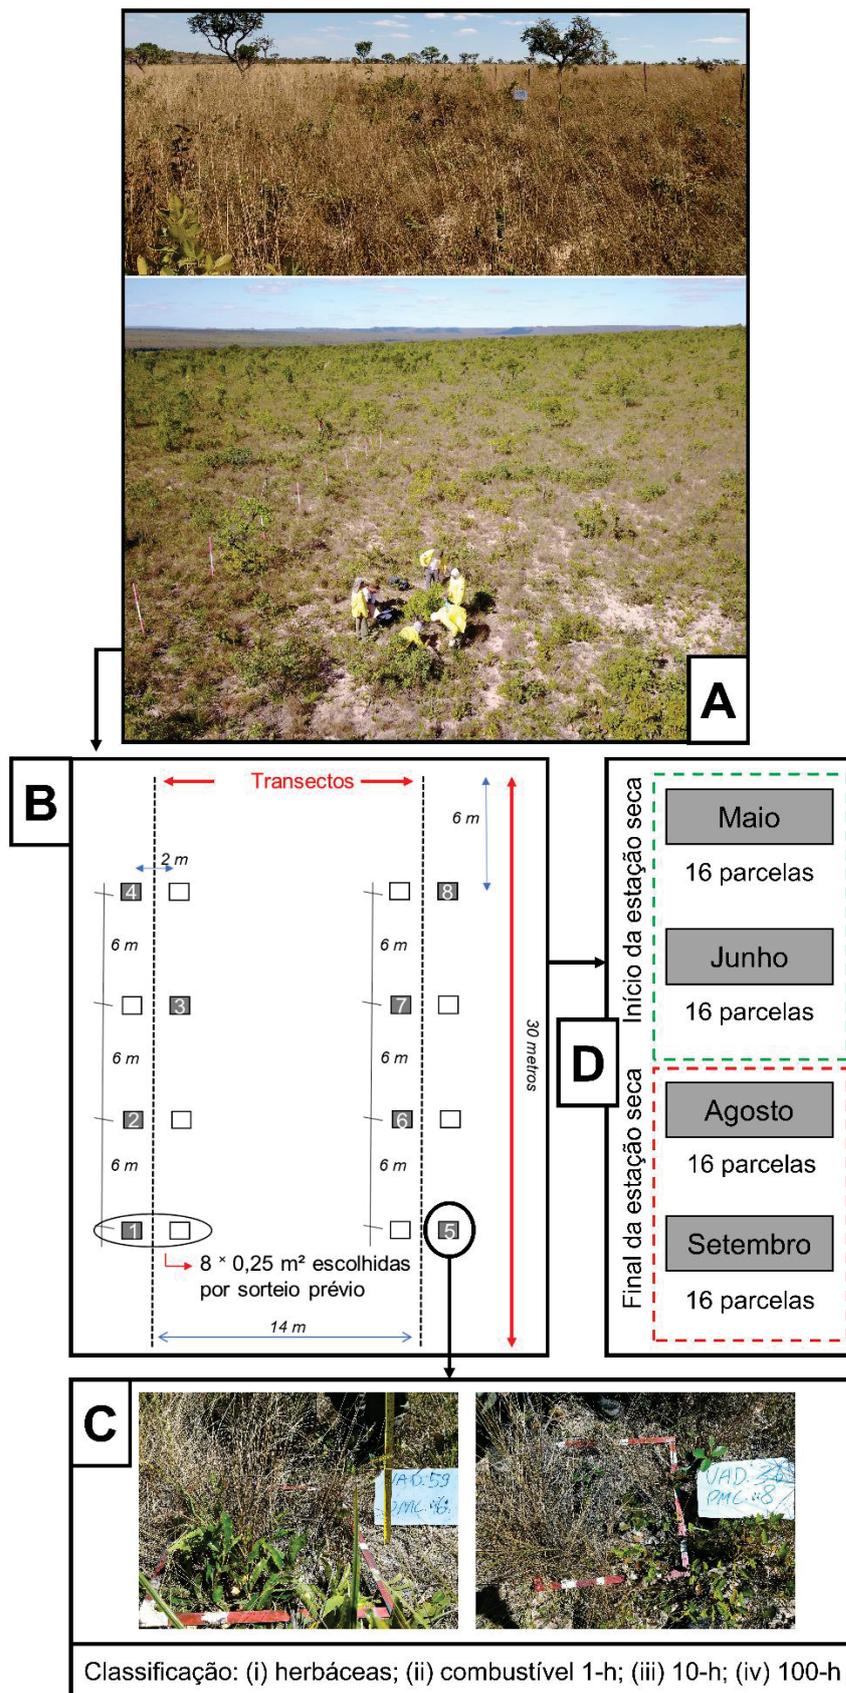
FONTE: O Autor (2024).

Na região do estudo a fitofisionomia que predomina é a do tipo campestre, das tipologias campo limpo, campo limpo úmido, campo sujo, campo sujo úmido e campo rupestre (ARRUDA; VON BEHR, 2002; RIBEIRO; WALTER, 2008). O tipo de solo predominante é de areias quartzosas, ou neossolo quartzarênico, com textura de areia ou areia franca a pelo menos dois metros de profundidade, podendo ter até 15% de argila. O relevo apresenta uma variação de relativamente plano a suavemente ondulado, com cotas médias de altitude entre 300 e 500 metros (SANTOS et al., 2013).

3.2 LEVANTAMENTO DE CAMPO

O levantamento de campo das variáveis de carga do material combustível superficial foi realizado através da instalação de unidades de amostragem de dados, as quais possuíam dois transectos de 30 metros cada. Através de marcações nos transectos, eram instalados por meio de sorteio prévio 8 subamostragens, denominadas de parcelas de material combustível, nas quais, o combustível era coletado pelo método destrutivo. Tais subamostragens tinham 0,25 m² de área (0,5 x 0,5 m) para que fosse realizada uma amostragem mais ampla, proporcionando uma maior variabilidade de combustível amostrado, em um tempo consumido menor (Figura 3).

FIGURA 3 - DELINEAMENTO EXPERIMENTAL UTILIZADO NAS COLETAS DE MATERIAL COMBUSTÍVEL



FONTE: O Autor (2024).

Assim, foram coletadas 128 unidades de amostragens de dados no total, o que totalizou 1.024 parcelas de material combustível. No entanto, para o objetivo de estimar valores de carga de material combustível por meio de imagens de satélite, foram escolhidas 64 unidades de amostragens de dados, tendo em vista a localização das parcelas e seus respectivos distanciamentos entre si. Foram observados distanciamentos superiores a 100 m de distância um do outro.

As amostragens destrutivas foram realizadas separando-se o material de acordo com seu estado fisiológico (vivo e morto) dentre diferentes classes de diâmetro (*timelag*), de acordo com metodologia proposta por Schroeder e Buck (1970) e Brown; Oberheu e Johnston (1982). Desta maneira, a classificação para combustíveis vivos foi realizada da seguinte forma: (i) material herbáceo vivo (HV); (ii) material lenhoso vivo de 1-h (LV1); (iii) material lenhoso vivo de 10-h (LV2); e (iv) material lenhoso vivo de 100-h (LV3). De maneira semelhante à classificação para combustível vivo, para combustíveis mortos a classificação foi a seguinte: (i) material herbáceo morto (HM); (ii) material lenhoso morto de 1-h (LM1); (iii) material lenhoso morto de 10-h (LM2); e (iv) material lenhoso morto de 100-h (LM3). Porém, para as classes LV2, LV3, LM2 e LM3 não foram discutidos os valores de carga, pois, além de suas quantidades insignificantes em relação às demais classes, o objetivo do presente estudo foi mensurar classes de combustível finos (< 0,7 cm de diâmetro) que exercem maiores influências no comportamento do fogo. Além das classes mencionadas, também, foram analisados valores de combustíveis totais vivos (V07; < 0,7 cm de diâmetro) e mortos (M07; < 0,7 cm de diâmetro) e carga total de combustível (Tot07; < 0,7 cm de diâmetro).

De cada classe de combustível era separada uma subamostra acondicionada em saco de papel *kraft*, devidamente identificada e determinada sua respectiva massa em balança digital antes de ser levadas à secagem. Após as coletas de campo, todas as subamostras eram submetidas a secagem em laboratório em estufa a 75 °C por um período de 48 horas. Posteriormente era determinada a massa seca e o conteúdo de umidade do combustível, a qual foi obtida através da resultante da razão entre a diferença da massa úmida com a massa seca, na base seca, e então transformada para porcentagem.

3.3 OBTENÇÃO E PROCESSAMENTO DAS IMAGENS DE SATÉLITE

As imagens utilizadas no presente estudo são do satélite Landsat 8 OLI, baixadas de forma gratuita da plataforma *EarthExplorer* (earthexplorer.usgs.gov) da *United States Geological Survey* (USGS). As imagens obtidas foram de datas aproximadas às das amostragens de campo durante quatro coletas realizadas durante o período seco, nos meses de maio, junho, agosto e setembro. Cabe ressaltar que essas imagens foram utilizadas para a realização das análises de mistura espectral (AMS).

Após a obtenção das imagens, elas passaram pelo processo de correção atmosférica, para a devida eliminação das interferências da atmosfera na extração dos dados, e obtenção dos valores de reflectância (LIANG; FANG; CHEN, 2001; RICHTER, 1996). Os dados de reflectância de superfície Landsat 8 OLI foram gerados usando o algoritmo *Land Surface Reflectance Code* (LaSRC) (VERMOTE et al., 2018). Os valores de reflectância foram obtidos das bandas do sensor Landsat 8 OLI nos seguintes canais: (i) azul (0,45–0,51 μm), (ii) verde (0,53–0,59 μm), (iii) vermelho (0,64–0,67 μm), (iv) infravermelho próximo (0,85–0,88 μm), e (v) infravermelho de ondas curtas (1,57–1,65 μm e 2,11–2,29 μm). A etapa seguinte às correções atmosféricas foi a realização das composições coloridas, que seriam utilizadas nas etapas subsequentes do trabalho. A composição da imagem de Landsat 8 OLI, que se utilizou na coleta inicial para as análises de mistura espectral, foi a composição 7 (infravermelho médio – SWIR 2), 5 (infravermelho próximo), 4 (vermelho).

Para extração dos valores de reflectância das bandas e para o cálculo dos índices de vegetação foi utilizada a plataforma de processamento de dados geoespaciais em nuvem *Google Earth Engine* (GEE). A plataforma do GEE possibilita um fácil acesso a recursos computacionais de alta performance para processamento em larga escala de base de dados geoespaciais (GORELICK et al., 2017). Desta maneira, os dados foram extraídos de diferentes imagens, das diferentes bandas espectrais e calculado os diversos índices de vegetação ao mesmo tempo, de forma mais rápida e sem a utilização da memória física do computador.

A extração dos valores dos *pixels* associados com as parcelas de campo, foram obtidos de uma janela de 3 x 3 *pixels*, no entorno do *pixel* de referência (*pixel* associado à parcela de campo). Desta forma, foram extraídos os valores medianos dentre os *pixels* de cada poligonal de 3 x 3 *pixels* ligadas às parcelas de campo

(CHRYSAFIS et al., 2017; CHUVIECO et al., 2002; HELMER et al., 2010; JI et al., 2012; MAIN-KNORN et al., 2013; MARSELIS et al., 2018; PROPASTIN, 2012). Os dados eram exportados e tabulados, de forma a associar as informações das parcelas coletadas em campo, com as informações da análise de mistura espectral, a reflectância e os índices de vegetação calculados.

3.4 CÁLCULO DE ÍNDICES DE VEGETAÇÃO (IVS)

A partir da combinação das reflectâncias nas diferentes bandas espectrais, foram calculados índices de vegetação (IVs). Os IVs são eficientes meios de obter informações empíricas de sensores multiespectrais e são comumente utilizados em diversos estudos científicos com o objetivo de melhor explicar ou determinar o comportamento de específicas variáveis da vegetação (e.g. DAVIDSON; WANG; WILMSHURST, 2006; JI et al., 2012a; VAN WAGTENDONK; ROOT, 2010; YEBRA et al., 2013, 2018). Na Tabela 1 são apresentados os índices de vegetação calculados e suas respectivas fórmulas.

TABELA 1 - ÍNDICES DE VEGETAÇÃO CALCULADOS NO ESTUDO

(continua)

N	Índice de Vegetação	Fórmula para cálculo	Referência
01	Índice de Vegetação por Diferença Normalizada (NDVI)	$\frac{\rho_{ivp} - \rho_{vm}}{\rho_{ivp} + \rho_{vm}}$	Rouse et al. (1974)
02	Índice de Resistência Atmosférica Visível (VARI)	$\frac{\rho_{vd} - \rho_{vm}}{\rho_{vd} + \rho_{vm} - \rho_{az}}$	Gitelson et al. (2002)
03	Índice Verde Visível (VI _{green})	$\frac{\rho_{vd} - \rho_{vm}}{\rho_{vd} + \rho_{vm}}$	
04	Razão simples (SR)	$\frac{\rho_{ivp}}{\rho_{vm}}$	Birth e Mcvey (1968)
05	Índice de Pigmento Insensível à Estrutura (SIPI)	$\frac{\rho_{ivp} - \rho_{az}}{\rho_{ivp} + \rho_{vm}}$	Peñuelas; Filella e Gamon (1995)
06	Índice de Vegetação Ajustado para o Solo (SAVI)	$\frac{(1 + L) * (\rho_{ivp} - \rho_{vm})}{L + \rho_{ivp} + \rho_{vm}}$	Huete (1988)
07	Índice de Água por Diferença Normalizada (NDWI)	$\frac{\rho_{vd} - \rho_{ivp}}{\rho_{vd} + \rho_{ivp}}$	Gao (1996)

FONTE: O Autor (2024).

TABELA 2 - ÍNDICES DE VEGETAÇÃO CALCULADOS NO ESTUDO

(conclusão)

N	Índice de Vegetação	Fórmula para cálculo	Referência
08	Índice Infravermelho de Diferença Normalizada (NDII6)	$\frac{\rho_{ivp} - \rho_{swir1}}{\rho_{ivp} + \rho_{swir1}}$	Hunt e Rock (1989)
09	Taxa de Queima Normalizada (NBR)	$\frac{\rho_{ivp} - \rho_{swir2}}{\rho_{ivp} + \rho_{swir2}}$	
10	Índice de Vegetação Modificado (MVI)	$\frac{\rho_{ivp} - 1,2\rho_{vm}}{\rho_{ivp} + \rho_{vm}}$	Paltridge e Barber (1988)
11	Razão Simples Modificada (MSR)	$\frac{\frac{\rho_{ivp} - 1}{\rho_{vm}}}{\sqrt{\frac{\rho_{ivp}}{\rho_{vm}} + 1}}$	Chen (1996)
12	Índice de estresse de umidade (MSI)	$\frac{\rho_{swir}}{\rho_{ivp}}$	Rock et al. (1986)
13	Índice de Água Normalizado Modificado (MNDWI)	$\frac{\rho_{vd} - \rho_{swir1}}{\rho_{vd} + \rho_{swir1}}$	Han-Qiu (2005)
14	Integral (INT)	$(\rho_{az} * W_{az}) + (\rho_{vd} * W_{vd}) + (\rho_{vm} * W_{vm}) + (\rho_{swir1} * W_{swir1}) + (\rho_{swir2} * W_{swir2})$	Chuvieco et al. (2002)
15	Índice Global de Umidade da Vegetação (GVMI)	$\frac{(\rho_{ivp} + 0,1) - (\rho_{swir1} + 0,02)}{(\rho_{ivp} + 0,1) + (\rho_{swir1} + 0,02)}$	Davidson; Wang e Wilmshurst (2006)
16	Índice de Vegetação Aprimorado (EVI)	$2,5 * \frac{(\rho_{ivp} - \rho_{vm})}{(\rho_{ivp} + C_1 * \rho_{vm} - C_2 * \rho_{az} + L)}$	Huete et al. (1997)
17	Derivado – banda 5 (ivp); banda 6 (swir1) (DER ₅₆)	$\frac{\rho_{ivp} - \rho_{swir1}}{\sigma_{ivp} - \sigma_{swir1}}$	Danson et al. (1992)
18	Derivado – banda 4 (vm); banda 5 (ivp) (DER ₄₅)	$\frac{\rho_{vm} - \rho_{ivp}}{\sigma_{vm} - \sigma_{ivp}}$	
19	Derivado – banda 3 (vd); banda 4 (vm) (DER ₃₄)	$\frac{\rho_{vd} - \rho_{vm}}{\sigma_{vd} - \sigma_{vm}}$	
20	Derivado – banda 2 (az); banda 3 (vd) (DER ₂₃)	$\frac{\rho_{az} - \rho_{vd}}{\sigma_{az} - \sigma_{vd}}$	

FONTE: O Autor (2024).

Em que:

 ρ_{ivp} = reflectância da região do infravermelho próximo (0,85 – 0,88 μm); ρ_{vm} = reflectância da região do vermelho (0,64 – 0,67 μm); ρ_{vd} = reflectância da região do verde (0,53 – 0,59 μm);

ρ_{az} = reflectância da região do azul (0,45 – 0,51 μm);

ρ_{swir1} = reflectância da região do infravermelho de ondas curtas – SWIR 1 (1,57 – 1,65 μm);

ρ_{swir2} = reflectância da região do infravermelho de ondas curtas – SWIR 2 (2,11 – 2,29 μm);

W_{az} = largura da banda na região do azul (0,06 μm)

W_{vd} = largura da banda na região do verde (0,06 μm)

W_{vm} = largura da banda na região do vermelho (0,03 μm)

W_{swir1} = largura da banda na região do infravermelho de ondas curtas – SWIR 1 (0,08 μm)

W_{swir2} = largura da banda na região do infravermelho de ondas curtas – SWIR 2 (0,18 μm)

σ_{ivp} = comprimento da onda na região do infravermelho próximo

σ_{vm} = comprimento da onda na região do vermelho

σ_{vd} = comprimento da onda na região do verde

σ_{az} = comprimento da onda na região do azul

σ_{swir1} = comprimento da onda na região do infravermelho médio – SWIR 1

C_1 e C_2 = coeficientes de correção dos efeitos atmosféricos para o vermelho (6) e azul (7,5), respectivamente

L = fator de correção para interferência do solo (1)

3.5 ANÁLISE DE MISTURA ESPECTRAL

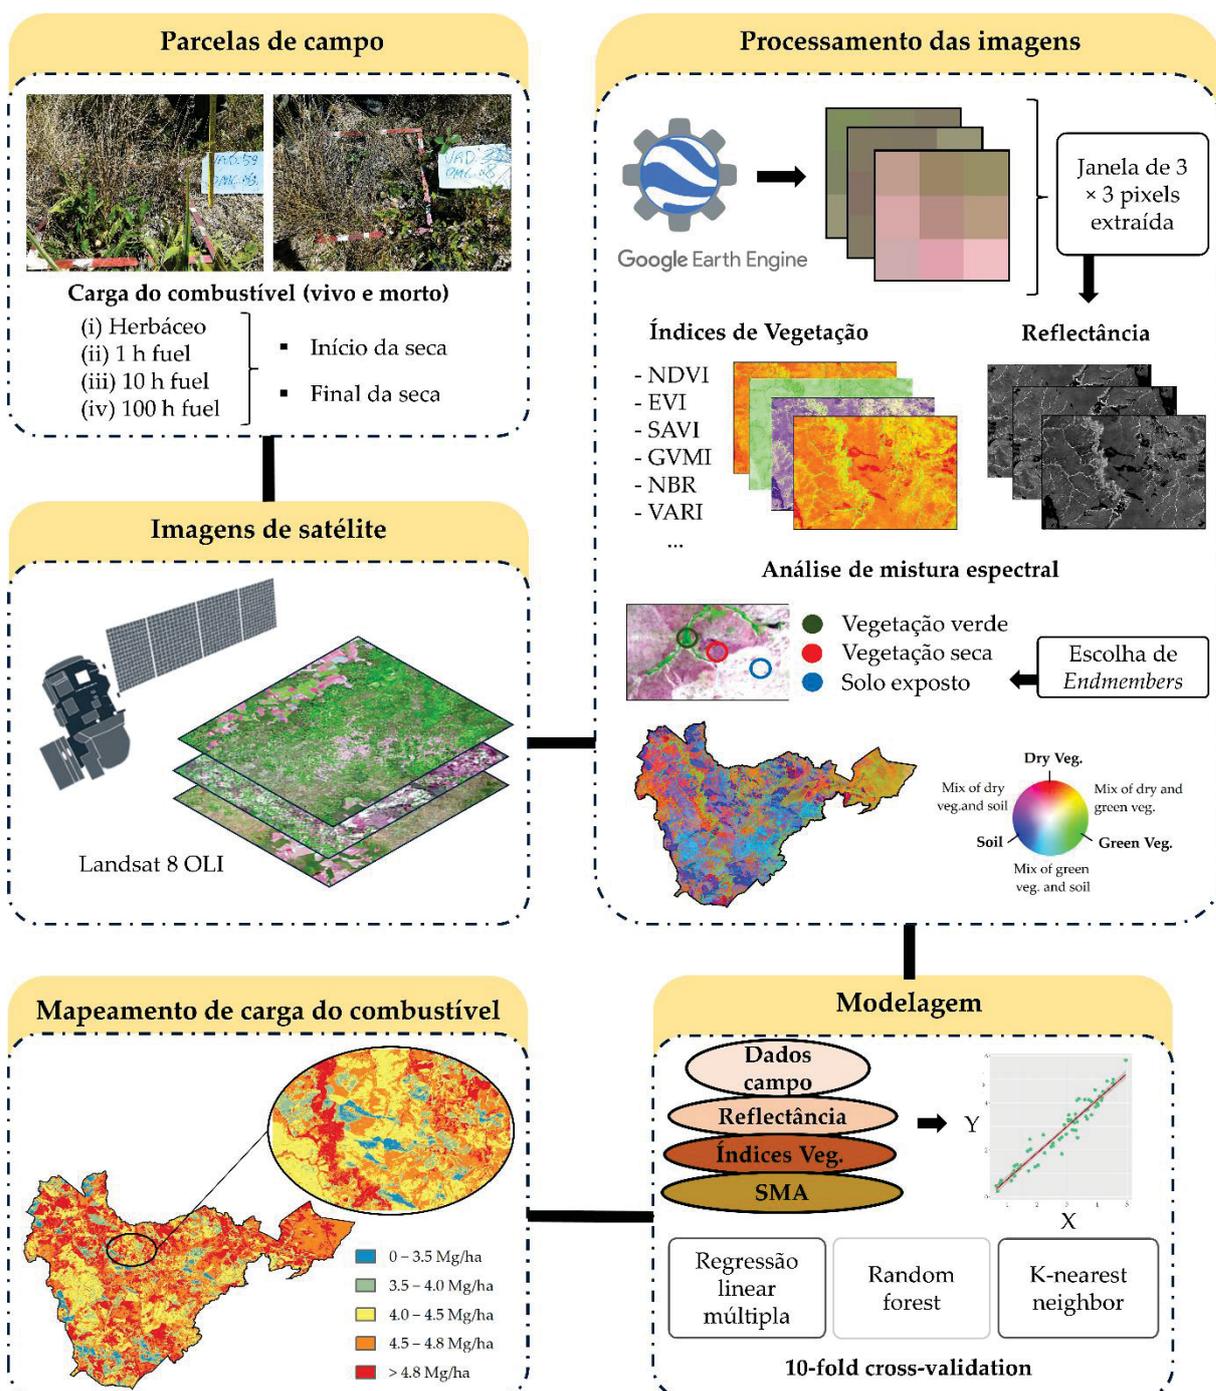
Após o processamento das imagens de satélite, foi dado início à criação de uma biblioteca espectral. Para que isso fosse possível, primeiramente, os alvos da superfície que foram objetivos das análises de mistura espectral (AMS) foram divididos em: (i) vegetação seca (fração vegetação seca); (ii) vegetação verde (fração vegetação verde) e; solo exposto (fração solo).

Assim, de cada alvo, foram selecionados vários candidatos a “*pixels* puros” denominados de *endmembers*. Desta forma, com base no comportamento espectral específico de cada alvo, foram delimitadas regiões de interesse (ROI – *regions of interest*), cujas reflectâncias apresentassem comportamentos espectrais mais fiéis possíveis à curva espectral característica do respectivo alvo.

Para o alcance dos objetivos aqui propostos, foram escolhidos *endmembers* em seis imagens representativas dos quatro meses da estação seca abordados no presente estudo (maio, junho, agosto e setembro), sendo das datas: 05/05/2017; 06/06/2017; 22/06/2017; 24/07/2017; 09/08/2017; e 10/09/2017. Assim, com todos os candidatos a *pixels* puros das feições desejadas escolhidos com base nas curvas espectrais, deu-se início ao processo de escolha dos *endmembers* com base em suas

métricas estatísticas com a utilização de *software* específico. Tal procedimento foi realizado com base na metodologia de análise de mistura espectral de múltiplos *endmembers* (MESMA -*Multiple Endmember Spectral Mixture Analysis*). Na Figura 4 é apresentada uma síntese do processamento dos dados provenientes do sensoriamento remoto.

FIGURA 4 - SÍNTESE DO PROCESSAMENTO DOS DADOS PROVENIENTES DO SENSORIAMENTO REMOTO



FONTE: O Autor (2024).

As seleções dos *endmembers* mais representativos foi feita com base nos menores valores de EAR (*Endmember Average RMSE* – Erro Quadrático Médio dos Endmembers) e MASA (*Minimum Average Spectral Angle* – Ângulo Espectral Médio Mínimo) apresentados. Desta maneira, foram analisadas diferentes configurações de *endmembers*, tendo em vista as diferentes condições meteorológicas apresentadas durante o período seco.

Assim, as conformações dos diferentes grupos de *endmembers* foram testadas de acordo com os seguintes grupos: (i) 1 (hum) *endmember* por feição (frações de vegetação seca, vegetação verde e solo); (ii) 1 (hum) *endmember* por mês de coleta (maio, junho, agosto e setembro); (iii) 3 (três) *endmembers* por mês de coleta; e (iv) 5 (cinco) *endmembers* por mês de coleta. No entanto, cabe ressaltar, que a definição de como seriam formadas as bibliotecas espectrais não foi objetivo do estudo e, desta forma, tal procedimento foi realizado com o intuito de selecionar uma biblioteca espectral que melhor representasse os dados apresentados no presente estudo, tendo em vista que foram realizadas coletas de dados em diferentes meses.

3.6 ANÁLISE ESTATÍSTICA DOS DADOS

Após o processamento dos dados das imagens de satélite, foram extraídas todas as informações que estavam associadas com os pontos de coletas de campo e então todos os dados extraídos foram tabulados e correlacionados através de análises de correlação de Pearson ($p < 0,05$; $p < 0,01$).

Após as análises de correlação deu-se início a análises de regressão linear múltiplas, tendo como variáveis dependentes a carga de material combustível, especialmente para as classes de combustível morto de 1-h (herbáceo morto; lenhoso morto de 1-h e; total morto de 1-h) e combustível total de 1-h (vivo e morto). Como variáveis independentes, foram utilizados os valores de fração provenientes das análises de mistura espectral (AMS), os valores de reflectância das imagens de satélite e, os índices de vegetação calculados.

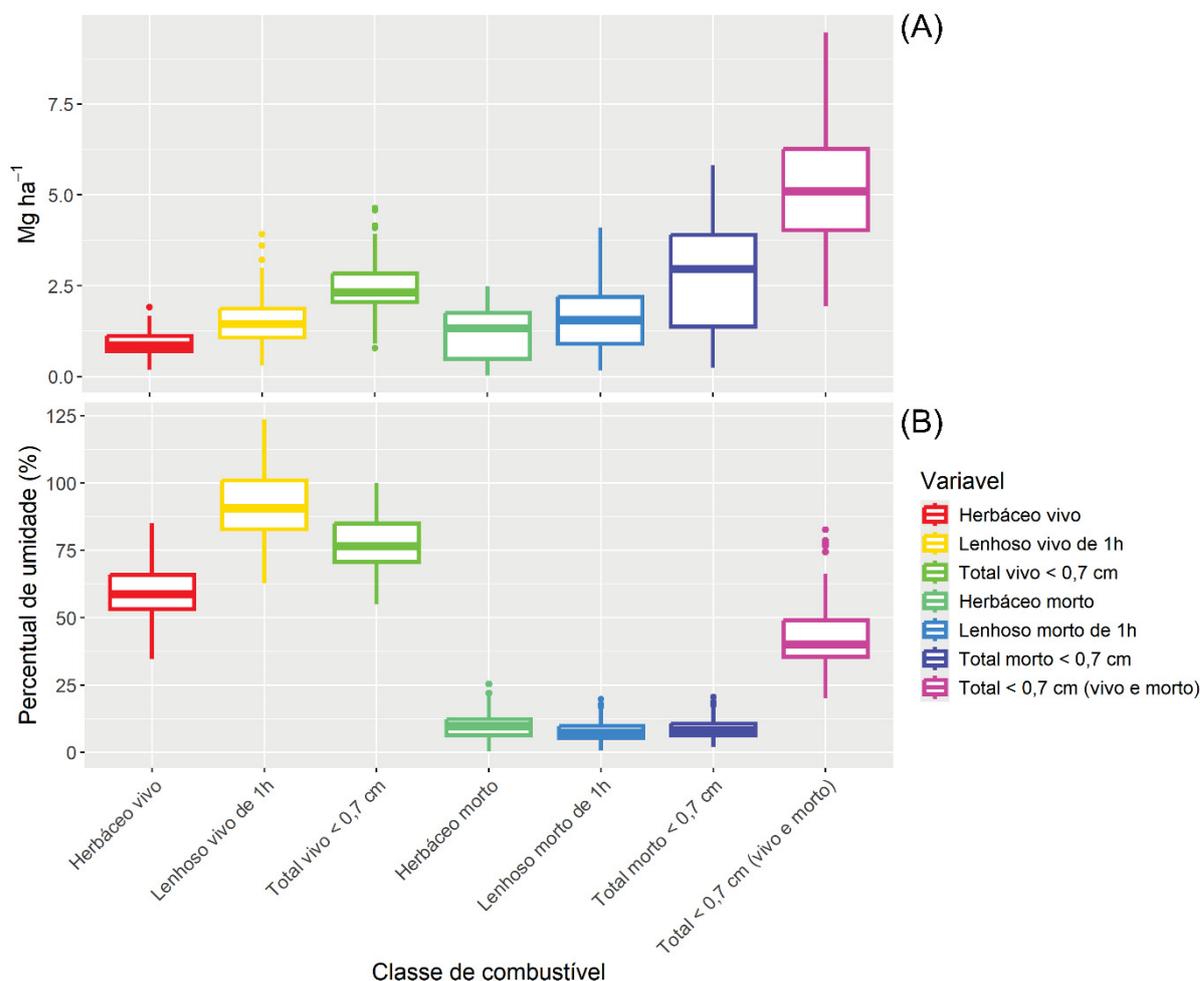
4 RESULTADOS

4.1 CARGA E UMIDADE DO COMBUSTÍVEL

Considerando os valores de carga de combustível, obtidos através das coletas de campo, baseando-se em todo o período de coleta dos dados de campo (meses de maio, junho, agosto e setembro), os valores variaram de 0,19 a 1,97 Mg ha⁻¹ considerando combustível herbáceo vivo (HV; CV = 7,0%) com uma média de 0,91 Mg ha⁻¹. Enquanto, para combustível lenhoso vivo de 1-h (LV1; CV = 26,2%), os valores tiveram uma variação de 0,3 a 3,9 Mg ha⁻¹ e um valor médio de 1,54 Mg ha⁻¹. Para combustível herbáceo morto (HM; CV = 7,6%) os quantitativos de carga variaram de 0,0 a 2,8 Mg ha⁻¹, apresentando uma média de 1,18 Mg ha⁻¹ e, quanto a combustível lenhoso morto de 1-h (LM1; CV = 27,1%) foi observada uma variação que foi de 0,17 a 4,1 Mg ha⁻¹ e valor médio de 1,59 Mg ha⁻¹.

Quantificando os subtotais de carga, para combustível total vivo de 1-h (V07), os valores foram de 0,78 a 4,64 Mg ha⁻¹, com média de 2,45 Mg ha⁻¹, enquanto para o combustível total morto de 1-h (M07) os valores de carga variaram de 0,24 a 5,81 Mg ha⁻¹, apresentando 2,77 Mg ha⁻¹ de média. Considerando os quantitativos de combustível total de 1-h (Tot07; CV = 12,3%) os valores foram de 1,9 a 9,6 Mg ha⁻¹ com média de 5,1 Mg ha⁻¹. Na Figura 5A são apresentados os *boxplots* referentes aos valores de carga do material combustível.

FIGURA 5 - *BOXPLOTS* ABRANGENDO OS DADOS DE CARGA E UMIDADE DO MATERIAL COMBUSTÍVEL



FONTE: O Autor (2024).

NOTA: (A) *Boxplots* referentes a carga do material combustível; e (B) *Boxplots* referentes a umidade do combustível.

Em relação aos valores de umidade do material combustível nas diferentes classes, observa-se que para combustível herbáceo vivo os percentuais de umidade tiveram uma média de 60,1%, variando de 34,8 a 85,0%, enquanto para a classe de lenhoso morto de 1-h a média de umidade foi de 91,3%, com valores variando de 62,8 a 123,6%. Considerando o combustível total vivo de 1-h, a média foi de 77,1%, variando de 54,9 a 100,1%.

Para combustível morto, a umidade da classe herbáceo morto apresentou uma média de 9,9%, podendo variar de 0,4 a 25,4% e para combustível lenhoso morto de 1-h a média foi de 8,0%, com uma variação de 0,8 a 19,8%. Ao considerar combustível total morto de 1-h, foram apresentados valores médios de umidade de 9,0%, podendo ir de 2,1 a 20,4%, enquanto o combustível total de 1-h (vivo e morto),

a média foi de 42,9% e sua variação foi de 19,9 a 82,7%. Tais comportamentos podem ser observados na Figura 5B.

4.2 CORRELAÇÕES

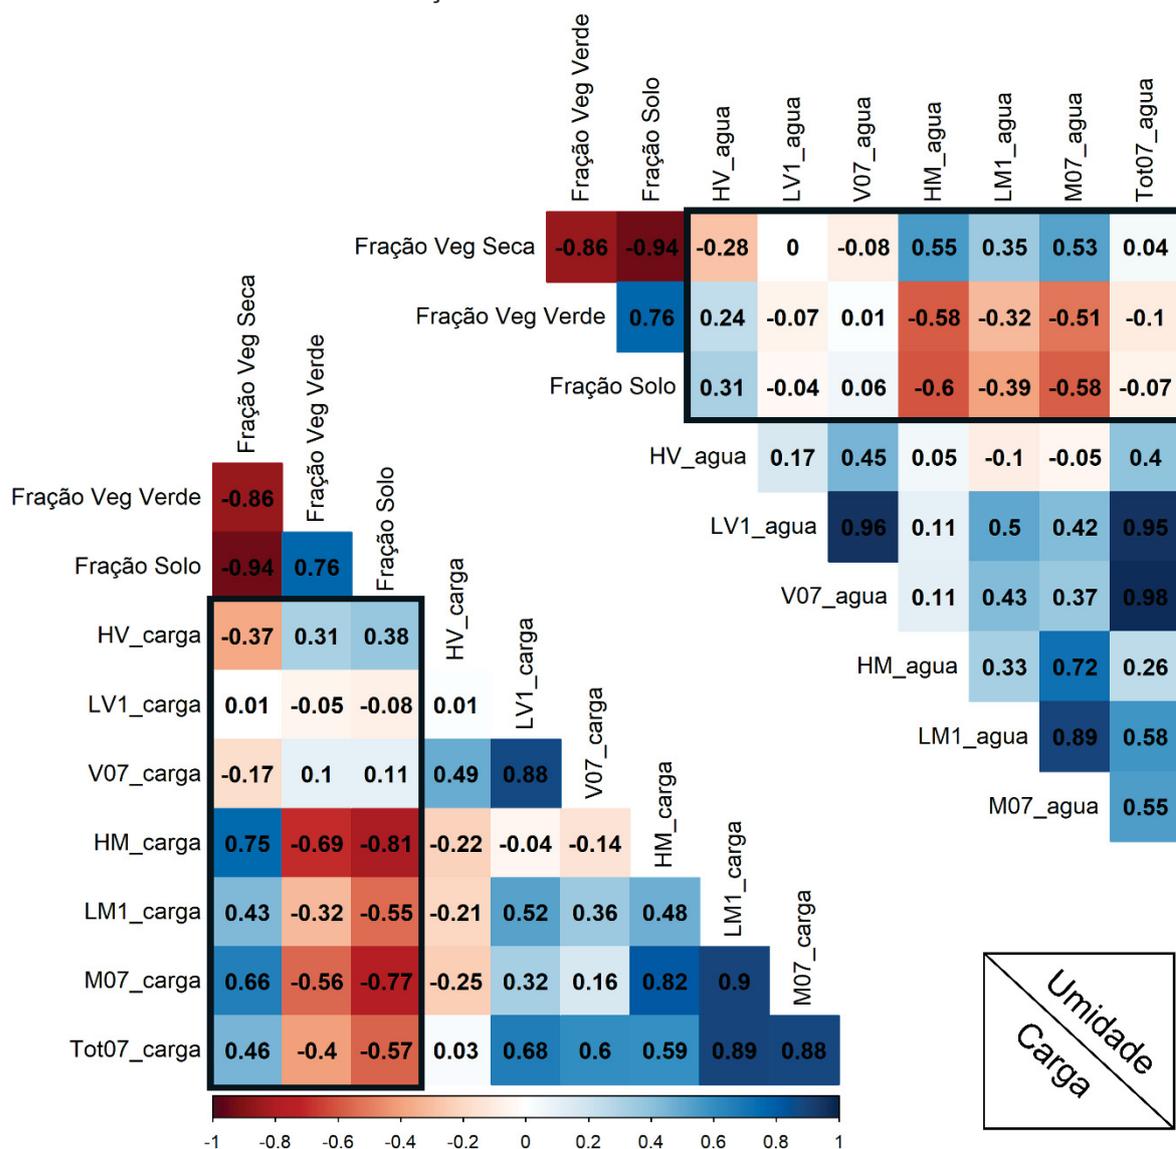
4.2.1 Correlações envolvendo os valores fração da análise de mistura espectral

Na Figura 6 são apresentadas as correlações de *Pearson* com destaque para as relações entre as variáveis obtidas da análise de mistura espectral (frações de vegetação seca, vegetação verde e solo) e as variáveis de carga do material combustível. Observa-se que as maiores correlações foram observadas para as variáveis de combustível morto, especialmente com carga de combustível herbáceo morto (HM) e combustível total morto < 0,7 cm (M07). A maior correlação observada foi entre HM e M07 vs. a fração solo (FS) com $r = -0,81$ e $r = -0,77$, respectivamente ($p < 0,01$). Pode-se notar, portanto, a existência de correlações inversas entre tais variáveis, ou seja, à medida que se aumenta a carga de ambas as variáveis (HM e M07), menor é a fração de solo exposto.

Em seguida, a correlação entre HM e M07 vs. a fração vegetação seca (FVS) foi de $r = 0,75$ e $r = 0,67$, respectivamente ($p < 0,01$), sendo, portanto, uma correlação direta. A relação entre HM e M07 vs. a fração de vegetação verde (FVV) foi de $r = -0,69$ e $r = -0,56$, respectivamente ($p < 0,01$).

As correlações inferiores com os valores de fração das análises de mistura espectral foram apresentadas para as classes de combustível vivo. As correlações entre a classe de combustível vivo de 1-h (LV1) foram não significativas com os valores de fração da AMS ($p > 0,05$). Em relação a classe de combustível herbáceo vivo (HV), as correlações foram de $r = -0,37$; $r = 0,31$ e; $r = 0,38$, respectivamente com FVS; FVV; e FS ($p < 0,01$).

FIGURA 6 - CORRELAÇÕES ENTRE A CARGA DE COMBUSTÍVEL NAS DIFERENTES CLASSES E OS VALORES FRAÇÃO DA ANÁLISE DE MISTURA ESPECTRAL



FONTE: O Autor (2024).

A classe de combustível total, a qual engloba as classes de combustível vivo e morto de diâmetro < 0,07 cm (HV, HM, LV1 e LM1), apresenta correlações de $r = 0,46$; $r = -0,40$; e $r = -0,57$, respectivamente com FVV; FVS; e FS ($p < 0,01$). As correlações, portanto, seguiram tendência semelhante às classes de combustível morto com relações diretas com fração de vegetação seca e inversas com as frações de vegetação verde e solo.

Observando as relações entre a umidade do material combustível e os valores fração da análise de mistura espectral, pode-se observar que as maiores correlações

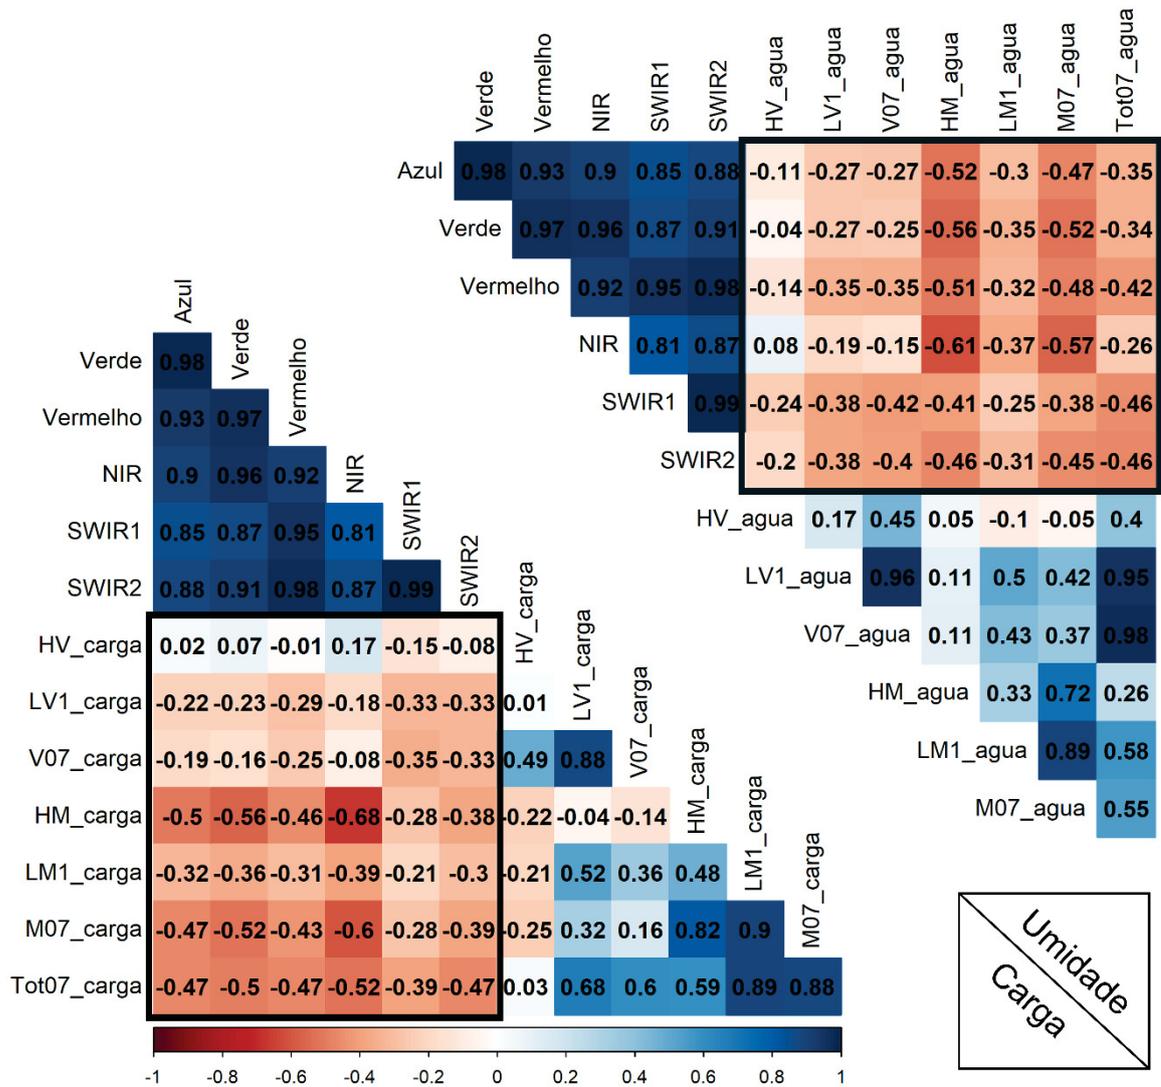
são referentes às classes de combustível morto, sendo que as correlações superiores foram entre umidade de HM e M07 vs. a fração solo que foram de $r = -0,60$ e $r = -0,58$, respectivamente ($p < 0,01$), conforme observado na Figura 6. Na sequência, a classe de umidade de HM desempenha correlações significativas com a fração vegetação verde e fração vegetação seca, com valores de, respectivamente, $r = -0,58$ e $r = -0,55$ ($p < 0,01$).

As correlações inferiores entre a umidade e as variáveis provenientes da análise de mistura espectral foram apresentadas entre as variáveis de combustível lenhoso vivo de 1-h, total vivo de 1-h e total de 1-h, não apresentando correlações significativas ($p < 0,01$; $p < 0,05$).

4.2.2 Correlações com valores de reflectância do sensor Landsat 8 OLI

Na Figura 7 são apresentadas as correlações entre os valores de reflectância das diferentes bandas do satélite Landsat 8 OLI e as variáveis de carga de material combustível. As maiores correlações observadas entre tais variáveis foram relações inversas entre a reflectância da região do infravermelho próximo (banda 5) vs. a carga de combustível herbáceo morto (HM) e combustível total morto de 1-h (M07), com $r = -0,68$ e $r = -0,60$, respectivamente ($p < 0,01$). Tais variáveis de combustível (HM e M07) também apresentaram correlação inversa de forma expressiva com a banda que abrange a região do verde do espectro eletromagnético, com, respectivamente, $r = -0,56$ e $r = -0,52$. Observa-se, portanto, maiores respostas da reflectância com as mudanças nas cargas das variáveis de combustível morto em áreas campestres do bioma Cerrado.

FIGURA 7 - CORRELAÇÕES ENTRE A CARGA DE COMBUSTÍVEL NAS DIFERENTES CLASSES E OS VALORES DE REFLECTÂNCIA DAS IMAGENS DE SATÉLITE



FONTE: O Autor (2024).

A exemplo dos resultados das relações encontradas entre as variáveis de combustível e os valores de fração da AMS, as correlações inferiores foram encontradas com a carga de combustível vivo. As correlações mais significativas com as variáveis de combustível vivo foram entre as classes LV1 e V07 com as bandas que abrangem as regiões do infravermelho de ondas curtas (bandas 6 e 7). Entre LV1 e as bandas 6 e 7 as relações foram de $r = -0,33$ para ambas as bandas ($p < 0,01$) e V07 as relações foram de $r = -0,36$ e $r = -0,33$, respectivamente para as bandas 6 e 7 ($p < 0,01$). Uma característica a ser ressaltada é que todas as correlações entre Tot07

e as variáveis de reflectância das bandas do Landsat 8 OLI foram significativas ($p < 0,01$).

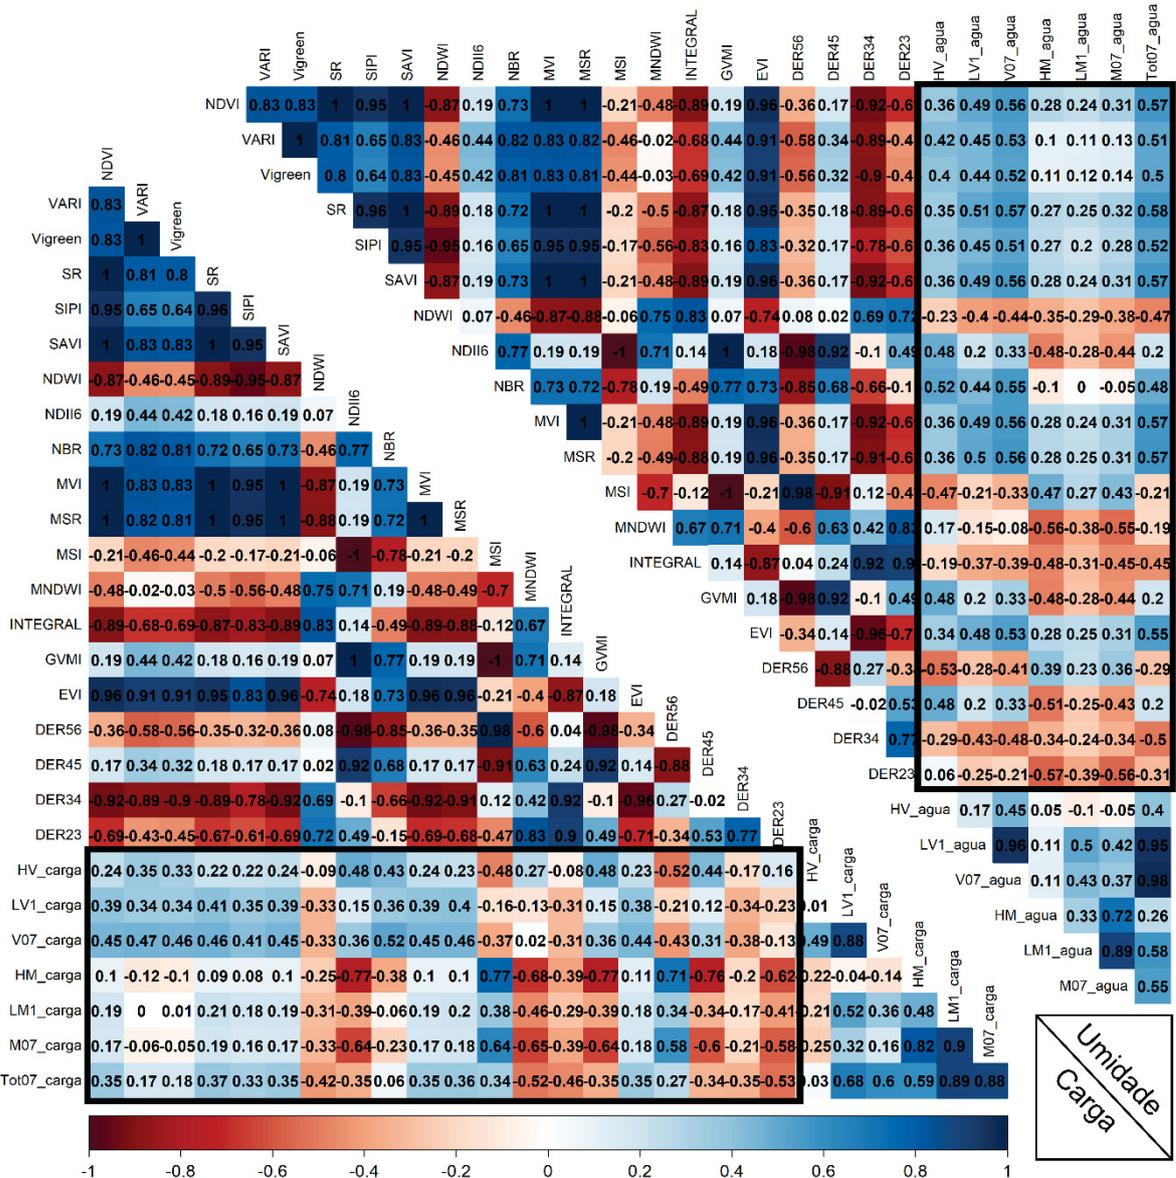
Considerando as relações entre a umidade do material combustível nas diferentes classes com as variáveis de reflectância das imagens de Landsat 8 OLI, pode-se notar que a umidade de combustível morto desempenha as maiores correlações, assim como para as variáveis provenientes das análises de mistura espectral. Dentre elas, destacam-se as correlações entre a umidade de combustível herbáceo morto (HM) com infravermelho próximo (NIR) de $r = -0,61$ ($p < 0,01$) e de HM com a reflectância da região do verde de $r = -0,56$ ($p < 0,01$). Enquanto a umidade de combustível herbáceo vivo e sua correlação com as variáveis de reflectância estão entre as mais baixas, não apresentando significância estatística (Figura 7).

4.2.3 Correlações envolvendo índices de vegetação (IVs)

Em relação as correlações das variáveis de carga de combustível com os valores dos índices de vegetação testados no presente estudo, sobressaíram-se os índices NDII6, MSI e GVMI. Na Figura 8 são apresentadas as correlações entre as variáveis de carga de combustível e os índices de vegetação (IVs) calculados. Assim como em exemplos anteriores, a carga de HM apresentou maiores correlações inversas com os índices NDII6 e GVMI ($r = -0,77$), bem como correlação direta com o índice MSI ($r = 0,77$; $p < 0,01$).

Entre as variáveis de combustível vivo, as maiores relações encontradas foram entre V07 e os índices NBR, VARI e SR, com correlações de $r = 0,52$; $r = 0,47$; e $0,46$, respectivamente ($p < 0,01$). O índice de vegetação NDVI apresentou maiores correlações com as variáveis de combustível vivo, especialmente LV1 ($r = 0,39$; $p < 0,01$) e V07 ($r = 0,45$; $p < 0,01$), porém, apresentando uma correlação significativa também com Tot07 ($r = 0,35$; $p < 0,01$). A exemplo do NDVI, o índice SAVI seguiu a mesma tendência apresentando maiores correlações com variáveis de combustível vivo, principalmente LV1 ($r = 0,39$; $p < 0,01$) e V07 ($r = 0,46$; $p < 0,01$), apresentando também correlação significativa com Tot07 de $r = 0,35$ ($p < 0,01$).

FIGURA 8 - CORRELAÇÕES ENTRE A CARGA DE COMBUSTÍVEL EM SUAS DIFERENTES CLASSES E OS ÍNDICES DE VEGETAÇÃO CALCULADOS



FONTE: O Autor (2024).

Analisando as relações quanto a quantidade total de combustível vivo e morto com diâmetro inferior a 0,7 cm (Tot07), observa-se que apenas com os índices de vegetação VARI e VI não apresentaram correlações significativas entre si, com valores de $r = 0,17$ e $r = 0,18$, respectivamente ($p > 0,05$). Tais índices de vegetação apresentaram relações significativas apenas com variáveis de combustíveis vivos, sendo os únicos índices (VARI e VI) que tiveram significância com todas as variáveis de combustíveis vivos aqui estudados (HV, LV1 e V07). Por outro lado, também foram observados índices de vegetação que apresentaram significância apenas com

variáveis de combustível morto, como foi o caso dos índices MNDWI e o DER23 ($p < 0,01$). Fora os índices VARI, VI, MNDWI e DER23, os quais tiveram uma interação mais específica com as classes de combustível vivo (VARI e VI) ou morto (MNDWI e DER23), os demais índices de vegetação tiveram interações significativas com pelo menos uma variável de combustível vivo e uma de combustível morto.

Em relação a umidade do material combustível e suas correlações com os índices de vegetação calculados, observam-se maiores relações lineares das variáveis de umidade do combustível com os índices SR, NDVI, SAVI, MVI e MSR. Tais IVs apresentaram superiores relações com a umidade de combustível Total de 1-h, com correlações positivas de $r = 0,58$ para SR e de $r = 0,57$ para NDVI, SAVI, MVI e MSR ($p < 0,01$). Destacam-se também os índices de vegetação DER23 e MNDWI, que tiveram as maiores correlações inversas de $r = -0,57$ e $r = 0,56$, respectivamente, com a umidade de combustível herbáceo morto ($p < 0,01$).

As relações menos expressivas entre as variáveis de umidade e índices de vegetação foram entre a umidade de combustível lenhoso morto de 1-h (LM1), sendo as correlações com os índices VARI, VIgreen, SIPI, SAVI, NBR e DER56 não apresentaram significância estatística ($p < 0,05$) (Figura 8).

5 DISCUSSÃO

As correlações apresentaram melhores desempenhos com as variáveis extraídas das imagens de satélite foram com as variáveis de combustível morto, em especial a carga e umidade de combustível herbáceo morto (HM) e o combustível total morto < 0,7 cm de diâmetro (M07). Um dos possíveis fatores para tal comportamento se dá pelo fato das coletas terem sido realizadas durante período morto e os combustíveis finos (*timelag* de 1-h) e secos serem predominantes nas áreas campestres de Cerrado.

Dentre as correlações obtidas entre os valores de fração da análise de mistura espectral e as cargas das diferentes classes de combustível, a mais expressiva foi entre combustível HM e a fração solo (FS) ($r = -0,81$ para carga e $r = -0,60$ para umidade), demonstrando a considerável influência da presença de solo exposto na relação com a carga e umidade de combustível herbáceo. Quando se avaliou a correlação da fração vegetação seca com a carga e umidade de combustível HM o resultado foi de $r = 0,75$ e $r = 0,55$ ($p < 0,01$), respectivamente para carga e umidade. As relações entre os valores fração, provenientes da análise de mistura espectral e as variáveis de carga de material combustível, se mostraram distintas das relações encontradas por Franke et al. (2018). Os autores obtiveram relações superiores entre a variável fração vegetação seca enquanto a fração solo apresentou uma relação inferior.

A reflectância da faixa do infravermelho próximo do sensor OLI (NIR; $0,85 \mu\text{m} - 0,87 \mu\text{m}$) demonstrou maior relação com as variáveis de carga e com a umidade do material combustível HM e total morto de 1-h. Tendo em vista a classe ser composta de vegetação fisiologicamente inativa ou com um baixo conteúdo de umidade, apresentou uma relação inversa com a reflectância do infravermelho próximo. Assim como em outras pesquisas, conforme destacam Danson e Bowyer (2004), que existe uma significativa relação inversa entre os comprimentos de onda individuais e o conteúdo de água da folha. Trabalhando com dados do sensor MSS do Landsat e correlacionando com fitomassa de vegetação herbácea verde, Merrill et al. (1993) encontraram melhores correlações com a banda verde ($0,5 \mu\text{m} - 0,6 \mu\text{m}$; $r = -0,64$), enquanto Zhang et al. (2018) apresentaram correlações superiores da biomassa com as bandas do verde e do vermelho utilizando dados Landsat (sensores TM e OLI). Hadi et al. (2016) observaram correlações superiores entre a cobertura de copa e a

reflectância da região do infravermelho médio de $r = -0,78$, não apresentando correlações com a região do infravermelho próximo.

Dentre as correlações entre os índices de vegetação testados e as variáveis de carga de combustível, os que se sobressaíram foram os índices NDII6, MSI e GVMI. Analisando as faixas espectrais que os índices utilizam em suas fórmulas, pode-se observar que ambos apresentam as faixas do infravermelho próximo (NIR; $0,85 \mu\text{m} - 0,87 \mu\text{m}$) e do infravermelho médio (SWIR1; $1,56 \mu\text{m} - 1,65 \mu\text{m}$), demonstrando a importância das regiões do infravermelho para estimativa de carga de combustível no presente estudo. A utilização das regiões do infravermelho próximo e infravermelho médio para estimativa de características da vegetação tem sido realizadas em diversas configurações (e.g. CHUVIECO et al., 2002; PETERSON; ROBERTS; DENNISON, 2008).

Segundo Chuvieco et al. (2002), as boas relações entre características de umidade do combustível e as regiões do infravermelho médio podem estar baseadas na presença de picos de alta absorção nessa região espectral. Na região do infravermelho próximo ($0,72 \mu\text{m} - 1,1 \mu\text{m}$), a reflectância é quase constante e a absorção da água é geralmente baixa, enquanto a região do infravermelho médio ($1,1 \mu\text{m} - 3,2 \mu\text{m}$) o conteúdo de água absorve consideravelmente a radiação incidente (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Trabalhando com a estimativa de biomassa acima do solo, Gao et al. (2020) obtiveram valores de correlação superiores com o NDVI de $r = 0,62$, enquanto Merrill et al. (1993) apresentaram valores de correlação entre a fitomassa de vegetação herbácea viva e o índice de vegetação calculado pela razão entre as bandas do infravermelho próximo e a banda do verde de $r = 0,57$. Considerando a relação do conteúdo de umidade com índices de vegetação, Danson e Bowyer (2004), encontraram maiores correlações de $r = 0,78$ e $0,58$ com os índices WI (*water index*) e NDWI (*normalised difference water index*), respectivamente. Trabalhando com modelagem de regressão linear para estimativas do conteúdo de umidade de combustíveis mortos utilizando o NDVI, Zormpas et al. (2017) obtiveram correlações significativamente baixas com $r = 0,01$.

No presente estudo, as relações entre NDVI e umidade do combustível foram positivas e apresentaram-se superiores com as classes de combustíveis vivos ($r = 0,36$ a $0,56$). García et al. (2020) obtiveram correlações positivas significativas entre NDVI e a umidade de combustível vivo, variando de $r = 0,22$ a $r = 0,87$ ($p < 0,001$).

Chuvieco et al. (2002) obtiveram maiores relações entre os índices Integral e *Wetness* com a umidade gramíneas, com valor de $r = 0,91$ ($p < 0,01$) e dentre as correlações entre umidade de gramíneas e a reflectância das bandas obtiveram valores superiores de $r = 0,88$, com as bandas do infravermelho médio (SWIR: $1,4 - 2,5 \mu\text{m}$).

As relações entre as variáveis de combustíveis vivos (herbáceo vivo, lenhoso vivo de 1-h e total vivo de 1-h) e as variáveis independentes do estudo foram inferiores às relações cujas variáveis dependentes são de combustíveis mortos (herbáceo morto, lenhoso morto de 1-h e total morto de 1-h). Dentre as faixas espectrais do sensor OLI, a que apresentou maior relação com as classes de combustível vivo foi a região do infravermelho médio (SWIR1; $1,56 \mu\text{m} - 1,65 \mu\text{m}$) seguida pela região do vermelho ($0,63 \mu\text{m} - 0,67 \mu\text{m}$). Das classes de combustível vivo, a região do infravermelho médio (SWIR1; $1,56 \mu\text{m} - 1,65 \mu\text{m}$) só não apresentou relações expressivas com a classe de combustível herbáceo vivo (HV). Uma possível explicação para tal comportamento, pode-se dar pelo fato da classe de combustível herbáceo vivo ser menos predominante durante a estação seca e se encontrar misturada com a vegetação herbácea seca, que é predominante nesse período. Por outro lado, as maiores relações com a classe de combustível vivo de 1-h (LV1) podem ser devido a maior umidade apresentada nesse tipo de material associada com a maior carga, bem como sua maior facilidade de distinção das plantas herbáceas, o que pode ter contribuído com a maior relação espectral.

Em relação ao efeito da resolução espectral, Casas et al. (2014) testaram combinações de múltiplas bandas com dados AVIRIS e demonstraram como o conteúdo de umidade do material combustível foi significativamente afetado pela combinação de bandas selecionadas, destacando que o comprimento de onda central e a largura da banda dos sensores podem afetar a estimativa da umidade de combustíveis vivos, apesar de estarem em uma mesma região espectral. O conteúdo de umidade está intimamente ligado ao nível de absorção de radiação eletromagnética na região do infravermelho médio, ou seja, quanto maior a umidade do material maior é a absorção da radiação e, conseqüentemente, menor a reflectância (CHUVIECO et al., 2002; PONZONI; SHIMABUKURO; KUPLICH, 2012).

6 CONCLUSÕES

As frações de vegetação seca (FVS), vegetação verde (FVV) e fração solo (FS) obtidas por metodologia de análise de mistura espectral (AMS) apresentaram relações significativas e mais expressivas com carga de material combustível herbáceo morto e combustível total < 0,7 cm (vivo e morto). A fração solo apresentou correlações superiores às demais frações, demonstrando a considerável influência da presença de solo exposto na determinação da carga de combustível a partir de imagens de satélite, em fitofisionomia campestre de Cerrado.

As variáveis de reflectância obtidas de imagens do satélite Landsat 8 OLI e os índices de vegetação calculados apresentaram as maiores relações com as classes de combustíveis mortos. As melhores relações foram da reflectância da faixa do infravermelho próximo (NIR), dentre as bandas do Landsat 8 OLI e, os índices de vegetação que se sobressaíram apresentaram as regiões do infravermelho próximo (NIR) e infravermelho de ondas curtas (SWIR1) em suas formulações. A utilização de índices de vegetação melhorou as relações com as classes de combustíveis vivos.

REFERÊNCIAS

- ARRUDA, M. B.; VON BEHR, M. **Jalapão**: Expedição científica e conservacionista. Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA). Brasília, 2002. 93p.
- BIRTH, G. S.; MCVEY, G. R. Measuring the Color of Growing Turf with a Reflectance Spectrophotometer1. **Agronomy Journal**, [S. l.], v. 60, n. 6, p. 640–643, 1968. DOI: 10.2134/AGRONJ1968.00021962006000060016X.
- BROWN, J. K.; OBERHEU, R. D.; JOHNSTON, C. M. Handbook for inventorying surface fuels and biomass in the Interior West. **Gen. Tech. Rep. INT-129. Ogden, UT: U.S. Department of Agriculture, Forest Service, Intermountain Forest and Range Experimental Station**. 48 p., [S. l.], v. 129, 1982. DOI: 10.2737/INT-GTR-129.
- CASAS, A.; RIAÑO, D.; USTIN, S. L.; DENNISON, P.; SALAS, J. Estimation of water-related biochemical and biophysical vegetation properties using multitemporal airborne hyperspectral data and its comparison to MODIS spectral response. **Remote Sensing of Environment**, [S. l.], v. 148, p. 28–41, 2014. DOI: 10.1016/J.RSE.2014.03.011.
- CHEN, J. M. Evaluation of vegetation indices and a modified simple ratio for boreal applications. **Canadian Journal of Remote Sensing**, [S. l.], v. 22, n. 3, p. 229–242, 1996. DOI: 10.1080/07038992.1996.10855178.
- CHRYSAFIS, I.; MALLINIS, G.; GITAS, I.; TSAKIRI-STRATI, M. Estimating Mediterranean forest parameters using multi seasonal Landsat 8 OLI imagery and an ensemble learning method. **Remote Sensing of Environment**, [S. l.], v. 199, p. 154–166, 2017. DOI: 10.1016/J.RSE.2017.07.018.
- CHUVIECO, E.; RIAÑO, D.; AGUADO, I.; COCERO, D. Estimation of fuel moisture content from multitemporal analysis of Landsat Thematic Mapper reflectance data: Applications in fire danger assessment. **International Journal of Remote Sensing**, [S. l.], v. 23, n. 11, p. 2145–2162, 2002. DOI: 10.1080/01431160110069818.
- DANSON, F. M.; BOWYER, P. Estimating live fuel moisture content from remotely sensed reflectance. **Remote Sensing of Environment**, [S. l.], v. 92, n. 3, p. 309–321, 2004. DOI: 10.1016/J.RSE.2004.03.017.
- DANSON, F. M.; STEVEN, M. D.; MALTHUS, T. J.; CLARK, J. A. High-spectral resolution data for determining leaf water content. **International Journal of Remote Sensing**, [S. l.], v. 13, n. 3, p. 461–470, 1992. DOI: 10.1080/01431169208904049.
- DAVIDSON, A.; WANG, S.; WILMSHURST, J. Remote sensing of grassland–shrubland vegetation water content in the shortwave domain. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 8, n. 4, p. 225–236, 2006. DOI: 10.1016/j.jag.2005.10.002.

DUFF, T. J.; BELL, T. L.; YORK, A. Predicting continuous variation in forest fuel load using biophysical models: a case study in south-eastern Australia. **International Journal of Wildland Fire**, [S. l.], v. 22, n. 3, p. 318–332, 2012. DOI: 10.1071/WF11087.

FRANKE, J.; BARRADAS, A. C. S.; BORGES, M. A.; MENEZES COSTA, M.; DIAS, P. A.; HOFFMANN, A. A.; OROZCO FILHO, J. C.; MELCHIORI, A. E.; SIEGERT, F. Fuel load mapping in the Brazilian Cerrado in support of integrated fire management. **Remote Sensing of Environment**, [S. l.], v. 217, p. 221–232, 2018. DOI: 10.1016/J.RSE.2018.08.018.

GAO, B. C. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, [S. l.], v. 58, n. 3, p. 257–266, 1996. DOI: 10.1016/S0034-4257(96)00067-3.

GAO, X. et al. Using the random forest model and validated MODIS with the field spectrometer measurement promote the accuracy of estimating aboveground biomass and coverage of alpine grasslands on the Qinghai-Tibetan Plateau. **Ecological Indicators**, [S. l.], v. 112, p. 106114, 2020. DOI: 10.1016/J.ECOLIND.2020.106114.

GARCÍA, M.; RIAÑO, D.; YEBRA, M.; SALAS, J.; CARDIL, A.; MONEDERO, S.; RAMIREZ, J.; MARTÍN, M.P.; VILAR, L.; GAJARDO, J.; USTIN, S. A live fuel moisture content product from Landsat TM satellite time series for implementation in fire behavior models. **Remote Sensing**, [S. l.], v. 12, n. 11, p. 1714, 2020. DOI: 10.3390/RS12111714.

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, [S. l.], v. 80, n. 1, p. 76–87, 2002. DOI: 10.1016/S0034-4257(01)00289-9.

GONZÁLEZ-PÉREZ, J. A.; GONZÁLEZ-VILA, F. J.; ALMENDROS, G.; KNICKER, H. The effect of fire on soil organic matter—a review. **Environment International**, [S. l.], v. 30, n. 6, p. 855–870, 2004. DOI: 10.1016/J.ENVINT.2004.02.003.

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: 10.1016/J.RSE.2017.06.031.

GOULD, J. S.; LACHLAN MCCAWE, W.; PHILLIP CHENEY, N. Quantifying fine fuel dynamics and structure in dry eucalypt forest (*Eucalyptus marginata*) in Western Australia for fire management. **Forest Ecology and Management**, [S. l.], v. 262, n. 3, p. 531–546, 2011. DOI: 10.1016/J.FORECO.2011.04.022.

HADI; KORHONEN, L.; HOVI, A.; RÖNNHOLM, P.; RAUTIAINEN, M. The accuracy of large-area forest canopy cover estimation using Landsat in boreal region. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 53, p. 118–127, 2016. DOI: 10.1016/J.JAG.2016.08.009.

HAN-QIU, XU. A study on information extraction of water body with the modified normalized difference water index (MNDWI). **National Remote Sensing Bulletin**, [S. l.], v. 0, n. 5, p. 589–595, 2005. DOI: 10.11834/jrs.20050586.

HELMER, E. H.; RUZYCKI, T. S.; WUNDERLE, J. M.; VOGESSER, S.; RUEFENACHT, B.; KWIT, C.; BRANDEIS, T. J.; EWERT, D. N. Mapping tropical dry forest height, foliage height profiles and disturbance type and age with a time series of cloud-cleared Landsat and ALI image mosaics to characterize avian habitat. **Remote Sensing of Environment**, [S. l.], v. 114, n. 11, p. 2457–2473, 2010. DOI: 10.1016/J.RSE.2010.05.021.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, [S. l.], v. 25, n. 3, p. 295–309, 1988. DOI: 10.1016/0034-4257(88)90106-X.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; VAN LEEUWEN, W. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, [S. l.], v. 59, n. 3, p. 440–451, 1997. DOI: 10.1016/S0034-4257(96)00112-5.

HUNT, E. R.; ROCK, B. N. Detection of changes in leaf water content using Near- and Middle-Infrared reflectances. **Remote Sensing of Environment**, [S. l.], v. 30, n. 1, p. 43–54, 1989. DOI: 10.1016/0034-4257(89)90046-1.

INSTITUTO CHICO MENDES DE CONSERVAÇÃO DA BIODIVERSIDADE (ICMBio). **Plano de manejo para Estação Ecológica Serra Geral do Tocantins (EESGT)**. Brasília-DF, ICMBio, 2014.

JI, L.; WYLIE, B. K.; NOSSOV, D. R.; PETERSON, B.; WALDROP, M. P.; MCFARLAND, J. W.; ROVER, J.; HOLLINGSWORTH, Teresa N. Estimating aboveground biomass in interior Alaska with Landsat data and field measurements. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 18, n. 1, p. 451–461, 2012. DOI: 10.1016/J.JAG.2012.03.019.

KEANE, R. E.; BURGAN, R.; VAN WAGTENDONK, J. Mapping wildland fuels for fire management across multiple scales: Integrating remote sensing, GIS, and biophysical modeling. **International Journal of Wildland Fire**, [S. l.], v. 10, n. 4, p. 301–319, 2001. DOI: 10.1071/WF01028.

LIANG, S.; FANG, H.; CHEN, M. Atmospheric correction of Landsat ETM+ land surface imagery-Part I: Methods. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 39, n. 11, p. 2490–2498, 2001. DOI: 10.1109/36.964986.

MAIN-KNORN, M.; COHEN, W. B.; KENNEDY, R. E.; GRODZKI, W.; PFLUGMACHER, D.; GRIFFITHS, P.; HOSTERT, P. Monitoring coniferous forest biomass change using a Landsat trajectory-based approach. **Remote Sensing of Environment**, [S. l.], v. 139, p. 277–290, 2013. DOI: 10.1016/J.RSE.2013.08.010.

MARSELIS, S. M.; TANG, H.; ARMSTON, J. D.; CALDERS, K.; LABRIÈRE, N.; DUBAYAH, R. Distinguishing vegetation types with airborne waveform lidar data in a tropical forest-savanna mosaic: a case study in Lopé National Park, Gabon. **Remote**

Sensing of Environment, [S. l.], v. 216, p. 626–634, 2018. DOI: 10.1016/J.RSE.2018.07.023.

MERRILL, E. H.; BRAMBLE-BRODAHL, M. K.; MARRS, R. W.; BOYCE, M. S. Estimation of green herbaceous phytomass from Landsat MSS data in Yellowstone National Park. **Journal of Range Management**, [S. l.], v. 46, n. 2, p. 151–157, 1993. DOI: 10.2307/4002273.

MOLLICONE, D.; EVA, H. D.; ACHARD, F. Human role in Russian wild fires. **Nature**, [S. l.], v. 440, n. 7083, p. 436–437, 2006. DOI: 10.1038/440436a.

PALTRIDGE, G. W.; BARBER, J. Monitoring grassland dryness and fire potential in australia with NOAA/AVHRR data. **Remote Sensing of Environment**, [S. l.], v. 25, n. 3, p. 381–394, 1988. DOI: 10.1016/0034-4257(88)90110-1.

PEÑUELAS, J.; FILELLA, I.; GAMON, J. A. Assessment of photosynthetic radiation-use efficiency with spectral reflectance. **New Phytologist**, [S. l.], v. 131, n. 3, p. 291–296, 1995. DOI: 10.1111/J.1469-8137.1995.TB03064.X.

PETERSON, S. H.; ROBERTS, D. A.; DENNISON, P. E. Mapping live fuel moisture with MODIS data: a multiple regression approach. **Remote Sensing of Environment**, [S. l.], v. 112, n. 12, p. 4272–4284, 2008. DOI: 10.1016/J.RSE.2008.07.012.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. [s.l.]: Oficina de Textos: 2012. 160 p.

PROPASTIN, P. Modifying geographically weighted regression for estimating aboveground biomass in tropical rainforests by multispectral remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 18, n. 1, p. 82–90, 2012. DOI: 10.1016/J.JAG.2011.12.013.

RAO, K.; WILLIAMS, A. P.; FLEFIL, J. F.; KONINGS, A. G. SAR-enhanced mapping of live fuel moisture content. **Remote Sensing of Environment**, [S. l.], v. 245, p. 111797, 2020. DOI: 10.1016/j.rse.2020.111797.

RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do Bioma Cerrado. *Em: Cerrado: ecologia e flora*. 1. ed. Brasília-DF: Embrapa Cerrados, 2008. v. 1. 152–212.

RICCARDI, C. L.; OTTMAR, R. D.; SANDBERG, D. V.; ANDREU, A.; ELMAN, E.; KOPPER, K.; LONG, J. The fuelbed: a key element of the Fuel Characteristic Classification System This article is one of a selection of papers published in the Special Forum on the Fuel Characteristic Classification System. **Canadian Journal of Forest Research**, [S. l.], v. 37, n. 12, p. 2394–2412, 2007. DOI: 10.1139/X07-143.

RICHTER, R. A spatially adaptive fast atmospheric correction algorithm. **International Journal of Remote Sensing**, [S. l.], v. 17, n. 6, p. 1201–1214, 1996. DOI: 10.1080/01431169608949077.

ROBERTS, D. A.; DENNISON, P. E.; GARDNER, M. E.; HETZEL, Y.; USTIN, S. L.; LEE, C. T. Evaluation of the potential of Hyperion for fire danger assessment by

comparison to the airborne visible/infrared imaging spectrometer. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 41, n. 6, p. 1297–1310, 2003. DOI: 10.1109/TGRS.2003.812904.

ROCK, B. N.; VOGELMANN, J. E.; WILLIAMS, D. L.; VOGELMANN, A. F.; HOSHIZAKI, T. Remote detection of forest damage: plant responses to stress may have spectral “signatures” that could be used to map, monitor, and measure forest damage. **BioScience**, [S. l.], v. 36, n. 7, p. 439–445, 1986. DOI: 10.2307/1310339.

RODRIGUEZ-JIMENEZ, F.; LORENZO, H.; NOVO, A.; ACUÑA-ALONSO, C.; ALVAREZ, X. Modelling of live fuel moisture content in different vegetation scenarios during dry periods using meteorological data and spectral indices. **Forest Ecology and Management**, [S. l.], v. 546, p. 121378, 2023. DOI: 10.1016/j.foreco.2023.121378.

ROTHERMEL, R. C. A mathematical model for predicting fire spread in wildland fuels. **Forest Service - Rocky Mountain Research Station, Usda**, [S. l.], n. Research Paper INT-115, p. 1–48, 1972.

ROUSE, J. W. J.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. **Monitoring vegetation systems in the Great Plains with ERTS - NASA Technical Reports Server (NTRS)**. Hampton, VA, USA, 1974.

SANTOS, R. P.; CREMA, A.; SZMUCHROWSKI, M. A.; POSSAPP, J. J.; NOGUEIRA, C. C.; ASANO, K.; KAWAGUCHI, M.; DINO, K. **Atlas do corredor ecológico da região do Jalapão**. 2. ed. [s.l.]: Instituto Chico Mendes de Conservação da Biodiversidade, 2013.

SCHROEDER, M.; BUCK, C. Fire weather: a guide for application of meteorological information to forest fire control operations. **USDA Forest Service, Agriculture Handbook 360**, [S. l.], 1970.

SEPLAN. **Atlas do Tocantins: subsídios ao planejamento da gestão territorial**. 6. ed. Palmas: Governo do Estado do Tocantins, 2012.

VAN WAGTENDONK, J. W.; ROOT, R. R. The use of multi-temporal Landsat Normalized Difference Vegetation Index (NDVI) data for mapping fuel models in Yosemite National Park, USA. **International Journal of Remote Sensing**, [S. l.], v. 24, n. 8, p. 1639–1651, 2010. DOI: 10.1080/01431160210144679.

VERMOTE, E.; ROGER, J. C.; FRANCH, B.; SKAKUN, S. LASRC (Land Surface Reflectance Code): Overview, application and validation using MODIS, VIIRS, LANDSAT and Sentinel 2 data's. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], v. 2018- July, p. 8173–8176, 2018. DOI: 10.1109/IGARSS.2018.8517622.

YEBRA, M.; DENNISON, P. E.; CHUVIECO, E.; RIAÑO, D.; ZYLSTRA, P.; HUNT, E. R.; DANSON, F. M.; QI, Yi; JURDAO, S. A global review of remote sensing of live fuel moisture content for fire danger assessment: Moving towards operational products. **Remote Sensing of Environment**, [S. l.], v. 136, p. 455–468, 2013. DOI: 10.1016/J.RSE.2013.05.029.

YEBRA, M.; QUAN, X.; RIAÑO, D.; ROZAS LARRAONDO, P.; VAN DIJK, A. I. J. M.; CARY, G. J. A fuel moisture content and flammability monitoring methodology for continental Australia based on optical remote sensing. **Remote Sensing of Environment**, [S. l.], v. 212, p. 260–272, 2018. DOI: 10.1016/J.RSE.2018.04.053.

ZHANG, C.; DENKA, S.; COOPER, H.; MISHRA, D. R. Quantification of sawgrass marsh aboveground biomass in the coastal Everglades using object-based ensemble analysis and Landsat data. **Remote Sensing of Environment**, [S. l.], v. 204, p. 366–379, 2018. DOI: 10.1016/J.RSE.2017.10.018.

ZORMPAS, K.; VASILAKOS, C.; ATHANASIS, N.; SOULAKELLIS, N.; KALABOKIDIS, K. Dead fuel moisture content estimation using remote sensing. **European Journal of Geography**, [S. l.], v. 8, n. 5, p. 17–32, 2017.

CAPÍTULO 3 - ESTIMATIVA DA CARGA DO COMBUSTÍVEL SUPERFICIAL DE FITOFISIONOMIA CAMPESTRE DE CERRADO UTILIZANDO PRODUTOS DE LANDSAT 8 OLI

RESUMO

Técnicas e ferramentas que visam auxiliar as atividades de manejo do fogo no Cerrado são bastante escassas. Um exemplo disso é falta de ferramentas para a determinação de carga e composição do material combustível de maneira espacial e temporalmente precisas para um correto manejo do combustível e auxílio nas tomadas de decisão para realização de queimas prescritas. Este estudo apresenta os seguintes objetivos: (1) avaliar o uso de dados de imagens Landsat 8 OLI para estimar a carga de combustível superficial do Cerrado durante a estação seca, ajustando equações de regressão linear múltipla, (2) estimar a carga de combustível através de algoritmos *Random Forest* e *k-Nearest Neighbors* (k-NN) em comparação com análises de regressão, e (3) avaliar a importância de variáveis preditoras de imagens de satélite. Para isso, foram coletadas 64 unidades amostrais na Estação Ecológica Serra Geral do Tocantins, e os valores dos *pixels* associados às parcelas de campo foram extraídos em uma janela de 3×3 *pixels* ao redor do *pixel* de referência. Para as análises de regressão linear, os valores de R^2 variaram de 0,63 a 0,78 e os modelos ajustados pelo algoritmo *Random Forest* apresentaram valores de R^2 variando de 0,52 a 0,83, enquanto os valores de R^2 do algoritmo k-NN variaram de 0,30 a 0,68. Por meio da utilização do algoritmo *Random Forest* obteve-se melhoras nas métricas estatísticas de avaliação das estimativas de carga de combustível campestre de Cerrado, em relação às análises de regressão linear múltiplas. A variável fração solo (FS) exerceu o efeito mais significativo nas estimativas de carga de combustível superficial, seguida pelos índices de vegetação NDII, GVMI, DER56, NBR e MSI, todos os quais utilizam canais infravermelho próximo e infravermelho de ondas curtas em seus cálculos.

Palavras-chave: algoritmos; imagens de satélite; processamento de imagens; mapas de acúmulo; estimativa do combustível

CHAPTER 3 - ESTIMATING THE SURFACE FUEL LOAD OF THE PLANT PHYSIOGNOMY OF THE CERRADO GRASSLAND USING LANDSAT 8 OLI PRODUCTS

ABSTRACT

Techniques and tools to assist fire management activities in the Cerrado are pretty scarce. An example is the lack of tools for determining the load and composition of fuel material spatially and temporally precisely, which is necessary for correct fuel management and assistance in decision-making to carry out prescribed burning. This study presents the following objectives: (1) to assess the use of data from Landsat 8 OLI images to estimate the fine surface fuel load of the Cerrado during the dry season by adjusting multiple linear regression equations, (2) to estimate the fuel load through Random Forest e k-Nearest Neighbors (k-NN) algorithms in comparison to regression analyses, and (3) to evaluate the importance of predictor variables from satellite images. Therefore, in the Serra Geral Ecological Station 64 sampling units were collected, and the pixel values associated with the field plots were extracted in a 3 × 3-pixel window surrounding the reference pixel. For multiple linear regression analyses, the R² values ranged from 0.63 to 0.78, while the R² values of the models fitted using the Random Forest algorithm ranged from 0.52 to 0.83 and the R² values of those fitted using the k-NN algorithm ranged from 0.30 to 0.68. The estimates made through multiple linear regression analyses showed better results for the equations adjusted for the beginning of the dry season (May and June). Adopting the Random Forest algorithm resulted in improvements in the statistical metrics of evaluation of the fuel load estimates for the Cerrado grassland relative to multiple linear regression analyses. The variable fraction-soil (FS) exerted the most significant effect on surface fuel load estimates, followed by the vegetation indices NDII, GVMI, DER56, NBR, and MSI, all of which use near-infrared and short-wave infrared channels in their calculations.

Keywords: algorithms; satellite imagery; image processing; fuel load maps; fuel estimation

1 INTRODUÇÃO

O fogo é uma característica de comum ocorrência no bioma Cerrado, principalmente em fitofisionomias abertas nas quais predominam a vegetação herbácea e gramíneas (BROWN; OBERHEU; JOHNSTON, 1982). Segundo Miranda et al. (2009), os incêndios no Cerrado, como em outras savanas, podem ser caracterizados como incêndios superficiais, consumindo basicamente os combustíveis finos da camada de combustíveis herbáceos.

O material combustível, segundo Rothermel (1972), representa a matéria orgânica disponível para ignição e combustão, caracterizando o único fator ligado ao fogo que pode ser controlado pela ação do homem. O conhecimento das características do material combustível é essencial para a determinação do comportamento do fogo, bem como, nas tomadas de decisões em ações de manejo integrado do fogo e combate aos incêndios florestais. No entanto, a determinação das características do material combustível é temporal e espacialmente complexa (KANMEGNE TAMGA et al., 2022; KEANE et al., 2013). Segundo Li et al. (2022), a determinação das características do combustível demanda de altos custos e elevado tempo em sua amostragem.

Roberts et al. (2003) destacam que as características essenciais para o entendimento do comportamento do fogo são: o tipo de combustível, a biomassa do combustível, a umidade e a condição do combustível (vivos ou mortos). A carga de combustível é uma variável de extrema importância, sendo uma característica do combustível comumente utilizada em diversas estratégias de gerenciamento de incêndios, tais como: a avaliação e estimativa do perigo de incêndio e, predição do comportamento do fogo (KUKAVSKAYA et al., 2023; ROTHERMEL, 1972). A carga de combustível tem influência significativa na modelagem de estimativas de biomassa e carbono, sendo que o seu conhecimento pelos gestores de terras é fundamental (SZPAKOWSKI; JENSEN, 2019). No entanto, poucos são os estudos em ambiente de Cerrado envolvendo a determinação das características do material combustível.

Técnicas baseadas em sensoriamento remoto são importantes para a realização de estimativas de diversas características do material combustível e vem sendo cada vez mais estudadas e aprimoradas. Dentre as diversas técnicas baseadas em sensoriamento remoto, segundo Roberts et al. (2003), os produtos obtidos podem contribuir para a avaliação do perigo de incêndios florestais, incluindo: (i) medidas

diretas de umidade de combustível vivo; (ii) medidas de biomassa herbácea viva; (iii) medidas da condição do combustível; e (iv) classificações do tipo de combustível. Van Wagendonk e Root (2010) destacam que as informações a respeito do combustível são comumente apresentadas como mapas de modelos de combustível, em que, tais modelos de combustível são utilizados para determinar a carga, tamanho, profundidade e umidade de extinção de combustíveis.

Observa-se uma ampla realização de estudos com a estimativa de variáveis de material combustível através de produtos do sensoriamento remoto. No entanto, quando se trata de combustível superficial de ambientes campestres do bioma Cerrado, pode-se observar uma considerável escassez de estudos. Diversos estudos realizam a caracterização e estimativas de biomassa florestal utilizando imagens Landsat (e.g. BAO et al., 2022; FRAZIER et al., 2014; JI et al., 2012; LI et al., 2021; ZHANG et al., 2014), através de produtos MODIS (e.g. CUI et al., 2019; GAO et al., 2020) e por meio de sensor Lidar (e.g. GOLDBERGS et al., 2018; XU et al., 2018). Nota-se que os diversos estudos que utilizam produtos do sensoriamento remoto, em sua grande parte, estão relacionados com a caracterização de variáveis florestais e poucos deles trabalham com estimativas de variáveis de combustíveis superficiais, as quais estão mais relacionadas com a ocorrência de incêndios de superfície, muito recorrentes, principalmente, em áreas campestres e savânicas.

A utilização de índices de vegetação tem sido abordada de forma ampla, onde são utilizados tanto em estudos de biomassa quanto, principalmente, na determinação de umidade do material combustível (DENNISON et al., 2006; ZARCO-TEJADA; RUEDA; USTIN, 2003). Outros estudos envolvendo a utilização de técnicas de mistura espectral têm sido realizados (e.g. ROUTH et al., 2018; SOUSA; SMALL, 2017), porém, poucos relacionados com a determinação de características físicas de combustíveis superficiais, com exceção de Franke et al. (2018) que trabalharam com o mapeamento do acúmulo de combustíveis finos utilizando técnicas de mistura espectral.

O diferencial significativo do presente estudo é a estimativa indireta do combustível superficial fino, classificado por tipo e em combustível vivo e morto e seu comportamento durante a estação seca, diferindo entre o início e o final do período seco utilizando produtos de sensoriamento remoto. A maioria dos estudos que estimam a carga de combustível fazem a modelagem sem considerar diferentes tipos de combustível. Não consideram a sazonalidade entre outras épocas do ano ou

períodos mais críticos, não oferecendo informações vitais para estimativas de perigo de incêndios florestais. Poucos estudos consideram o uso de produtos de análise de mistura espectral associados a algoritmos de aprendizado de máquina na estimativa da carga combustível de gramíneas, principalmente em ambientes com alta variabilidade espaço-temporal, como o bioma Cerrado.

1.1 HIPÓTESES

O presente estudo foi baseado nas seguintes hipóteses:

- (i) Existe diferença entre o início e fim da estação seca nas avaliações estatísticas dos modelos de regressão linear múltiplos para estimativas de carga de combustível superficial em ambiente campestre de Cerrado utilizando imagens de Landsat 8 OLI;
- (ii) A utilização de métodos não paramétricos, em especial os algoritmos *Random Forest* e *k-Nearest Neighbors*, melhoram o desempenho das estimativas de carga de material combustível por meio de imagens de satélite, em relação aos modelos de regressão linear múltiplos.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Avaliação do uso de produtos de imagens de Landsat 8 OLI para estimativa de carga de material combustível superficial de fitofisionomia campestre de Cerrado, considerando o período de seca, por meio de ajuste de equações de regressão linear múltiplas e aplicação de algoritmos *Random Forest* e *k-Nearest Neighbors*.

2.2 OBJETIVOS ESPECÍFICOS

- (i) Avaliação da utilização dos valores de fração (*F-values*) provenientes de análise de mistura espectral (AMS) para estimativa de carga de material combustível por meio de análises de regressão linear;
- (ii) Verificar a viabilidade da utilização dos valores de reflectância e índices de vegetação para estimativa de carga do material combustível através do ajuste de análises de regressão linear;
- (iii) Avaliar o desempenho das equações de regressão linear múltiplas ajustadas para estimativa de carga de combustível nas diferentes classes, considerando o início e final da estação seca a partir dos produtos do sensor Landsat 8 OLI;
- (iv) Avaliar a utilização dos algoritmos *Random Forest* e *k-Nearest Neighbors* em comparação com as análises de regressão linear múltiplas para as estimativas da carga de combustível nas diferentes classes.

3 MATERIAL E MÉTODOS

O detalhamento das informações sobre a área de estudo, levantamento de campo, obtenção e processamento das imagens de satélite, cálculo de índices de vegetação e análise de mistura espectral são apresentadas na seção de Material e Métodos do capítulo 2 (Seções de 3.1 a 3.6).

3.1 ANÁLISE ESTATÍSTICA DOS DADOS

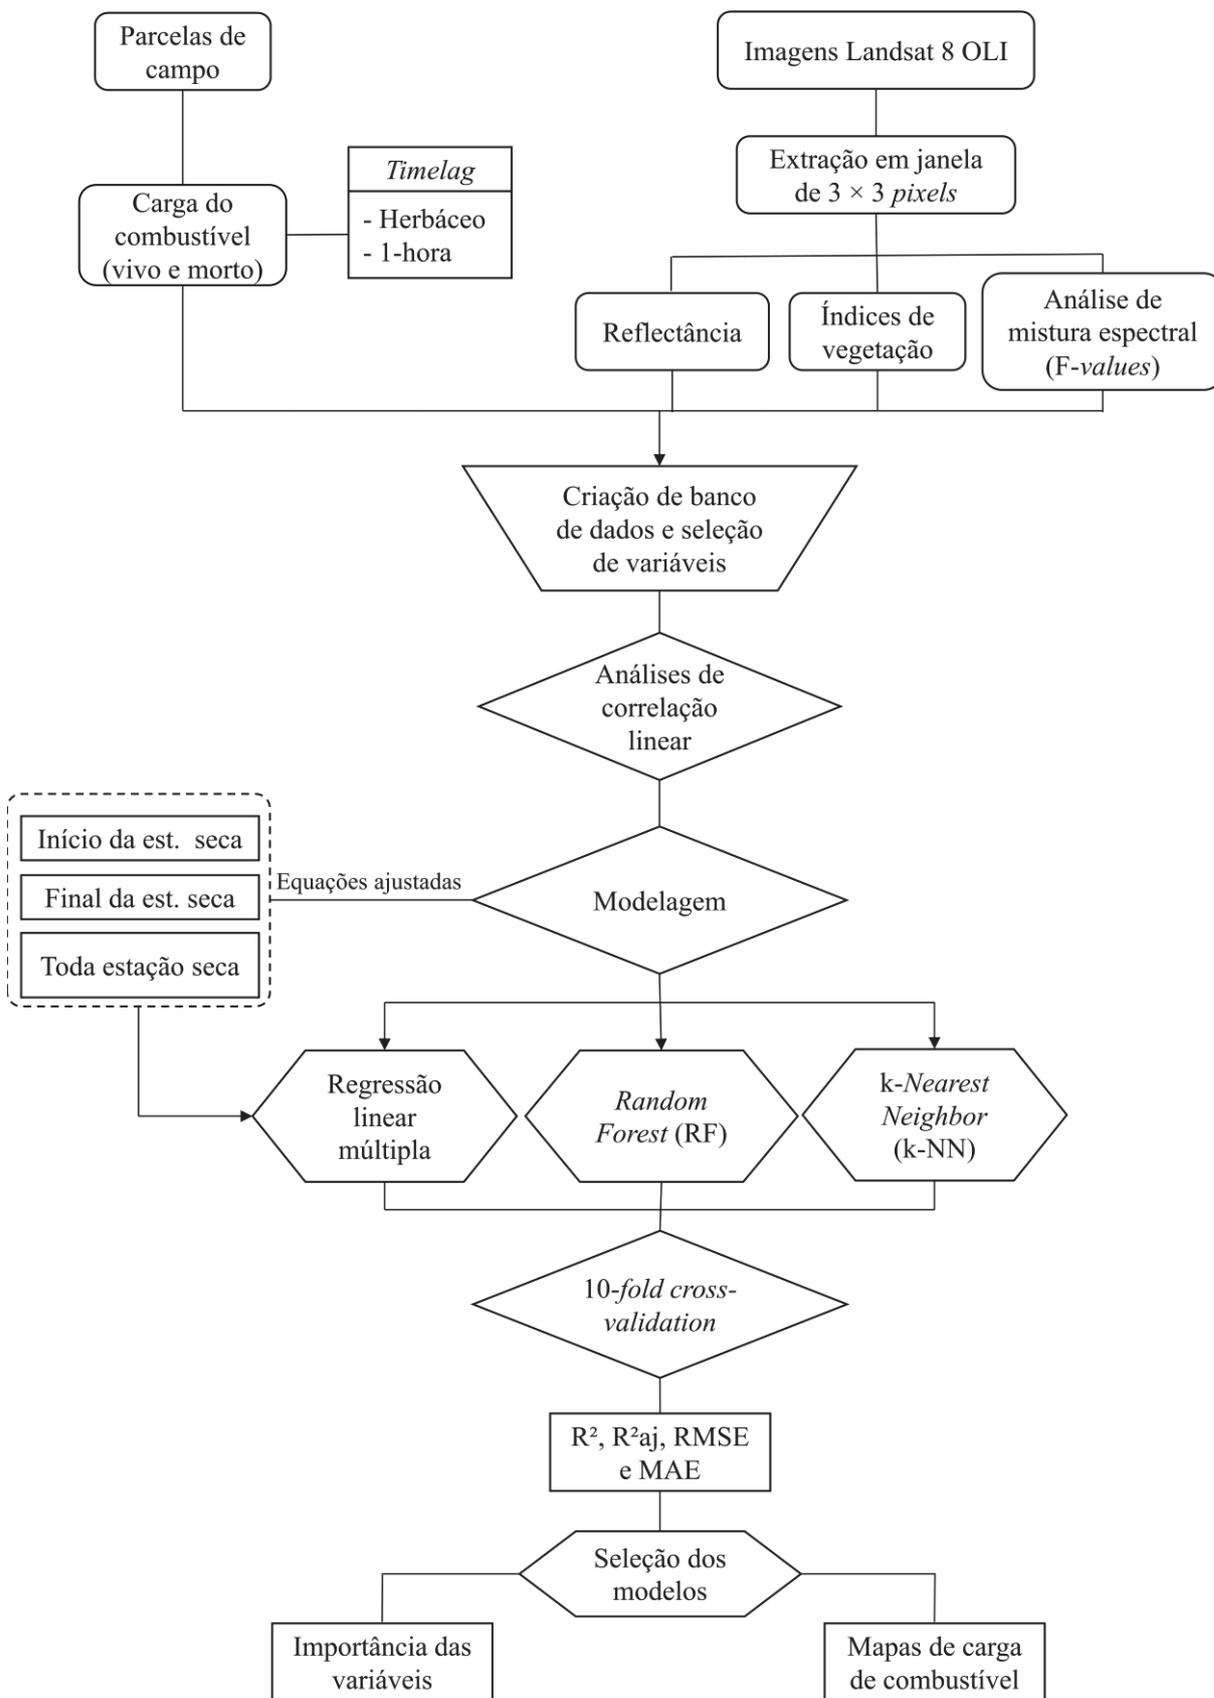
3.1.1 Análises de regressão linear múltiplas

Após as análises de correlação deu-se início a análises de regressão linear múltiplas, tendo como variáveis dependentes a carga de material combustível, especialmente para as classes de combustível morto de 1-h (herbáceo morto, lenhoso morto de 1-h e total morto de 1-h) e combustível total de 1-h (vivo e morto). Como variáveis independentes, foram utilizados os valores de fração provenientes das análises de mistura espectral (AMS), os valores de reflectância das imagens de satélite e os índices de vegetação calculados.

Os ajustes das equações de regressão linear múltiplas foram realizados da seguinte maneira: (i) ajuste de equações com dados coletados nos meses iniciais da estação seca (maio e junho); (ii) ajuste de equações com dados coletados nos meses finais da estação seca (agosto e setembro); e (iii) ajuste de equações considerando todo o período da estação seca. Os ajustes também foram realizados levando-se em consideração todas as variáveis independentes e através do método *stepwise*. As equações que não apresentaram significância a 5% não foram apresentadas ($p < 0,05$).

A avaliação das equações de melhor ajuste do estudo foi feita através da análise dos maiores valores do coeficiente de determinação ajustados (R^2_{aj}), os quais variam de 0 a 1. Outra métrica estatística analisada para comparação dos modelos foi baseada nos menores valores do erro padrão da estimativa percentual ($Sy_x\%$), além da análise dos gráficos de dispersão das equações. Na Figura 9 é apresentado o fluxograma da metodologia aplicada no estudo.

FIGURA 9 - FLUXOGRAMA DA METODOLOGIA APLICADA NO ESTUDO



FONTE: O Autor (2024).

3.1.2 Algoritmo *Random Forest*

Foi utilizado o algoritmo de aprendizado de máquina *Random Forest* (RF), o qual é um método não paramétrico desenvolvido por Breiman (2001), que vem sendo amplamente utilizado em diversos estudos (e.g. CHRYSAFIS et al., 2017; FRAZIER et al., 2014; GAO et al., 2020; ZENG et al., 2019). O algoritmo RF combina diversas árvores preditoras, nas quais, cada árvore é gerada por um vetor aleatório independentemente amostrado e com distribuição semelhante para todas as árvores na floresta (CARVALHO JUNIOR et al., 2016). Comparado com os métodos tradicionais de regressão linear, os modelos *Random Forest* demonstram várias vantagens em estimativas de biomassa acima do solo, tal como a melhora na acurácia e redução de problemas não lineares (LI et al., 2017).

Antes de submeter os dados à aplicação do modelo, os dados foram devidamente tratados e minerados, para que o modelo não ficasse sobrecarregado com variáveis de pouca relevância. Assim, os dados foram então importados para o programa R. Primeiramente, os dados foram divididos em variáveis de treino e variáveis de teste, de forma aleatória, na proporção de 70% e 30%, respectivamente (GOLDBERGS et al., 2018). Desta forma, das 64 parcelas selecionadas para o estudo, 45 foram destinadas ao conjunto de treinamento e 19 ao conjunto de validação. Para Belgiu e Drăgu (2016), as amostras usadas para treinar os classificadores necessitam cumprir uma série de requisitos, dentre eles: (i) treinamento e validação dos dados devem ser estatisticamente independentes; (ii) treinamento das amostras devem ser classes balanceadas; (iii) o treinamento das amostras deve ser representativo das classes alvo; e (iv) as amostras de treinamento precisam ser grandes o suficiente para acomodar o número crescente de dimensões de dados.

Para implementar o *Random Forest*, dois parâmetros devem ser definidos: o número de árvores (*n_{tree}*) e o número de variáveis utilizadas em cada divisão (*m_{try}*). Em relação ao *n_{tree}*, no presente estudo observou-se que a precisão da predição pelo algoritmo *Random Forest* não aumentou significativamente quando o *n_{tree}* apresentou valores superiores a 1.000. O *n_{tree}* ideal definido foi igual a 1.000 para garantir a confiabilidade dos resultados da predição sem afetar a eficiência computacional (OU; LEI; SHEN, 2019; THANH NOI; KAPPAS, 2017). Para *m_{try}*, os valores foram definidos como um terço do número total de variáveis preditoras

(BREIMAN, 2001; LIAW; WIENER, 2002; SUN et al., 2016; WANG et al., 2016). Estes variaram entre $mtry = 4$ e 5 para modelos ajustados com variáveis preditoras selecionadas pelo método *stepwise* e $mtry = 10$ para modelos ajustados com todas as variáveis preditoras. O pacote “*randomForest*” do programa R foi utilizado para aplicar o algoritmo.

Para a avaliação dos modelos ajustados pelo algoritmo RF, são apresentadas a importância exercida pelas variáveis preditoras em um determinado modelo, para estimativa de uma determinada variável dependente. A importância das variáveis foi avaliada quanto ao incremento no erro quadrado médio (% IncMSE), a qual, mede o efeito do potencial preditivo de uma variável quando esta é submetida a uma permutação aleatória. Em suma, tal métrica mostra o quanto a precisão do modelo diminui se determinada variável preditora for deixada de fora do modelo.

3.1.3 Algoritmo k-Nearest Neighbor

Outro algoritmo de aprendizado de máquina que foi utilizado, a fim de verificar a viabilidade na estimativa de carga de combustível a partir de produtos de imagens de satélite, foi o algoritmo k-Nearest Neighbors (k-NN). O algoritmo k-NN é utilizado para classificação e regressão e realiza previsões dos valores de variáveis pontuais com base na semelhança em um espaço covariável entre o ponto e outros pontos com valores observados das variáveis (GAO et al., 2018). A utilização do algoritmo k-NN associado com dados do sensoriamento remoto tem desempenhado um papel fundamental em estudos florestais com diversas aplicações nos inventários florestais de campo, buscando melhorar a acurácia das estimativas (OHMANN; GREGORY; ROBERTS, 2014; ZHANG et al., 2022).

O algoritmo k-NN foi aplicado empregando o pacote “*Caret*” no programa R. Existe um parâmetro essencial neste algoritmo, K, ou o número de vizinhos que precisam ser otimizados. Este parâmetro especifica o sistema de eleição no algoritmo k-NN, onde os K vizinhos mais próximos são selecionados e então se define o modelo de saída (AVAND et al., 2019). Os valores de K foram determinados com base nos valores mais baixos de RMSE e os valores ótimos foram escolhidos para cada variável de combustível estimada. A Tabela 4 fornece os valores K selecionados de cada variável de combustível estimada e os respectivos valores RMSE.

3.1.4 Validação das equações de regressão lineares

Foram submetidas ao processo de validação cruzada as equações que apresentaram melhores métricas quanto aos maiores valores de R^2_{aj} e menores de S_{yx} para cada variável de combustível morto de 1-h, em seus diferentes períodos da estação seca (início, final e em todo o período) em cada grupo de variáveis preditoras analisado (valores de fração, reflectância, índices de vegetação e a combinação de todas as variáveis independentes). A validação cruzada serve para avaliar o desempenho do modelo e fornece um estimador quase imparcial do erro de previsão (PFLUGMACHER; COHEN; KENNEDY, 2012). Desta forma, foi realizada a técnica de validação cruzada *k-fold cross validation*, com a utilização de 10 dobras (FUSHIKI, 2011; JI et al., 2012; RODRÍGUEZ; PÉREZ; LOZANO, 2010).

As métricas estatísticas de avaliação das equações validadas foram: (i) os valores do coeficiente de determinação ao quadrado (R^2); (ii) o coeficiente de determinação ao quadrado ajustado (R^2_{aj}); (iii) raiz do erro quadrático médio (RMSE – *root mean square error*); e (iv) o erro absoluto médio (MAE – *mean absolute error*).

4 RESULTADOS

4.1 ANÁLISES DE REGRESSÃO LINEAR MÚLTIPLAS

A construção de modelos para estimativa das variáveis de carga de material combustível foi iniciada com ajustes de equações de regressão lineares múltiplas. Primeiramente são apresentadas as equações de regressão separadamente para os diferentes grupos de variáveis independentes (valores de fração da análise de mistura espectral; reflectância das bandas e índices de vegetação) e depois com a combinação de todas as variáveis independentes do estudo. Além dos grupos de variáveis independentes, foram também ajustadas equações considerando o início da estação seca (meses de maio e junho), o final (meses de agosto e setembro) e para todo o período da estação seca.

Para a validação dos modelos de regressão linear múltiplas, foi realizada a técnica de validação cruzada *k-fold cross validation*, com a utilização de 10 dobras. Nas Tabelas 2 a 5 são apresentados os modelos em que foram realizadas validação cruzada, sendo que foram escolhidos para validação os melhores modelos para cada classe em cada período da estação seca (início, final e todo o período). Ou seja, foram validados todos os modelos ajustados pelo método *stepwise*, o qual obteve melhores desempenhos em todos os ajustes de regressão linear múltiplos.

4.1.1 Ajustes em função dos valores fração da análise de mistura espectral

Observa-se que as equações ajustadas com as variáveis da análise de mistura espectral (FVS, FVV, FS), obtiveram bons desempenhos no processo de validação cruzada e, no geral, melhoraram os valores de R^2 em relação às equações iniciais (não validadas). Dentre as equações validadas, observa-se a equação com melhor R^2 foi da variável de combustível total morto $< 0,7$ cm (M07) no período inicial da estação seca, com $R^2 = 0,89$. Para o final da estação seca, a equação com melhor desempenho foi para a classe herbáceo morto (HM), com R^2 de 0,82, e considerando toda a estação seca, a equação validada para estimativa de HM também obteve melhor desempenho com R^2 de 0,69 (Tabela 2).

TABELA 3 - MÉTRICAS ESTATÍSTICAS DA VALIDAÇÃO CRUZADA REALIZADA PARA OS MELHORES AJUSTES FEITOS PARA A ESTIMATIVA DE CARGA ATRAVÉS DE VALORES DE FRAÇÃO DA METODOLOGIA DE MISTURA ESPECTRAL

Per	Combustível estimado (y)	Variáveis predictoras (x)	R ²	R ² _{aj}	RMSE	MAE
1	Herbáceo morto	FS: fração solo; FVV: fração vegetação verde	0,69	0,67	0,44	0,37
	Lenhoso morto de 1-h	FVS: fração vegetação seca	0,80	0,79	0,60	0,49
	Total morto (< 0,7 cm)	FVS: fração vegetação seca	0,89	0,88	0,68	0,58
	Total (vivo e morto)	FS: fração solo	0,80	0,79	1,11	0,98
2	Herbáceo morto	FS: fração solo	0,82	0,82	0,27	0,23
	Lenhoso morto de 1-h	FS: fração solo; FVS: fração vegetação seca	0,67	0,64	0,68	0,57
	Total morto (< 0,7 cm)	FS: fração solo; FVS: fração vegetação seca	0,73	0,71	0,79	0,65
	Total (vivo e morto)	FS: fração solo; FVS: fração vegetação seca; FVV: fração vegetação verde	0,68	0,65	1,13	0,96
3	Herbáceo morto	FS: fração solo; FVS: fração vegetação seca; FVV: fração vegetação verde	0,69	0,67	0,39	0,31
	Lenhoso morto de 1-h	FS: fração solo; FVS: fração vegetação seca	0,45	0,43	0,69	0,55
	Total morto (< 0,7 cm)	FS: fração solo; FVS: fração vegetação seca	0,61	0,60	0,84	0,70
	Total (vivo e morto)	FS: fração solo; FVS: fração vegetação seca	0,39	0,37	1,33	1,05

FONTE: O Autor (2024).

NOTA: Per = Período da estação seca, onde: (1) Início da estação seca (maio e junho); (2) Final da estação seca (agosto e setembro); (3) Toda estação seca (maio a setembro).

Quanto ao combustível Total < 0,7 cm (vivo e morto) (Tot07) pode-se observar uma considerável queda em seus valores de R², partindo de 0,80 no período inicial da estação seca, alcançando um R² = 0,68 no final da seca e considerando todo o período de estiagem, o valor de R² da equação validada decresceu ainda mais, sendo de R² = 0,39 (p < 0,05). Nota-se, portanto, que dependendo da classe de material combustível, pode-se ter melhores desempenhos no início ou final da estação seca e, quando se considera todo o período, os valores decrescem em relação aos períodos de melhor desempenho.

4.1.2 Ajustes em função dos valores de reflectância das imagens de satélite

Na Tabela 3 são apresentadas as métricas das equações de regressão linear múltiplas validadas, considerando as variáveis de reflectância das bandas de Landsat

8 OLI como variáveis independentes. Observa-se que as equações desempenharam resultados satisfatórios quanto ao processo de validação ao passo que, a exemplo da validação dos modelos que consideravam os valores de fração das análises de mistura espectral (AMS), melhoraram os valores de R^2 em relação as equações antes do processo de validação.

Desta forma, analisando-se as métricas apresentadas na Tabela 3, constata-se que as equações que se destacaram foram para a estimativa de combustível herbáceo morto (HM) para o período final da estação seca e a equação ajustada para estimativa de combustível total morto com diâmetro inferior a 0,7 cm (M07) para o período inicial da seca. Ambas as equações tiveram valores de R^2 de 0,91 ($p < 0,05$).

TABELA 4 - MÉTRICAS ESTATÍSTICAS DA VALIDAÇÃO CRUZADA REALIZADA PARA OS MELHORES AJUSTES FEITOS PARA A ESTIMATIVA DE CARGA ATRAVÉS DE VALORES DE REFLECTÂNCIA DAS BANDAS DO SENSOR OLI LANDSAT 8

Per	Combustível estimado (y)	Variáveis predictoras (x)	R^2	R^2_{aj}	RMSE	MAE
1	Herbáceo morto	B5: nir; B6: swir1; B7: swir2	0,85	0,84	0,41	0,36
	Lenhoso morto de 1-h	B4: red; B6: swir1	0,81	0,80	0,59	0,48
	Total morto (< 0,7 cm)	B4: red; B6: swir1	0,91	0,90	0,61	0,52
	Total (vivo e morto)	B4: red; B6: swir1	0,80	0,79	1,13	0,98
2	Herbáceo morto	B2: blue; B3: green; B5: nir; B6: swir1; B7: swir2	0,91	0,89	0,25	0,21
	Lenhoso morto de 1-h	B6: swir1; B7: swir2	0,67	0,64	0,66	0,57
	Total morto (< 0,7 cm)	B2: blue; B3: green; B5: nir; B6: swir1; B7: swir2	0,65	0,59	0,78	0,66
	Total (vivo e morto)	B6: swir1; B7: swir2	0,66	0,64	1,07	0,92
3	Herbáceo morto	B2: blue; B3: green; B5: nir; B6: swir1; B7: swir2	0,77	0,75	0,36	0,29
	Lenhoso morto de 1-h	B4: red; B5: nir; B6: swir1; B7: swir2	0,49	0,46	0,73	0,59
	Total morto (< 0,7 cm)	B2: blue; B4: red; B5: nir; B6: swir1; B7: swir2	0,63	0,60	0,84	0,69
	Total (vivo e morto)	B4: red; B5: nir; B6: swir1; B7: swir2	0,47	0,44	1,37	1,13

FONTE: O Autor (2024).

NOTA: Per = Período da estação seca, onde: (1) Início da estação seca (maio e junho); (2) Final da estação seca (agosto e setembro); (3) Toda estação seca (maio a setembro).

Para combustível total com diâmetro inferior a 0,7 cm (vivo e morto - Tot07), a equação validada de melhor desempenho foi encontrada para o período inicial da

estação seca, com valor de R^2 de 0,80. Considerando o período final da estação seca, o R^2 decresce para 0,66 e em todo o período seco, o R^2 diminui mais uma vez para 0,47 ($p < 0,05$).

4.1.3 Ajustes em função dos índices de vegetação

Na Tabela 4 são apresentadas as métricas estatísticas das equações ajustadas em função dos valores dos índices de vegetação. Analisando os valores de R^2 , pode-se observar que os melhores desempenhos foram para as variáveis M07 e HM ajustadas para o período inicial da estação seca, com R^2 de 0,94 e de 0,91, respectivamente; enquanto para o período final os melhores valores foram de R^2 de 0,85 e de 0,79 para as variáveis HM e Tot07, respectivamente ($p < 0,05$).

TABELA 5 - MÉTRICAS ESTATÍSTICAS DA VALIDAÇÃO CRUZADA REALIZADA PARA OS MELHORES AJUSTES FEITOS PARA A ESTIMATIVA DE CARGA ATRAVÉS DE VALORES DE ÍNDICES DE VEGETAÇÃO

Per	Combustível estimado (y)	Variáveis predictoras (x)	R^2	R^2_{aj}	RMSE	MAE
1	Herbáceo morto	VARI; Vlgreen; SIPI; NBR; MSI; GVMI	0,91	0,90	0,35	0,31
	Lenhoso morto de 1-h	NDVI; VARI; Vlgreen; SR; SIPI; SAVI; NDWI; NDII6; NBR; MSR; MSI; EVI; DER45; DER23	0,89	0,80	0,39	0,34
	Total morto (< 0,7 cm)	NDVI; VARI; Vlgreen; SR; SIPI; SAVI; NDWI; EVI; DER56	0,94	0,92	0,49	0,42
	Total (vivo e morto)	VARI; Vlgreen; SR; SIPI; SAVI; NDWI; MSR; INTEGRAL; EVI; DER45	0,78	0,68	1,07	0,91
2	Herbáceo morto	VARI; Vlgreen; SR; SIPI; SAVI; MSR; MNDWI; DER56; DER45; DER23	0,85	0,79	0,31	0,29
	Lenhoso morto de 1-h	NDVI; VARI; Vlgreen; SAVI; NBR; INTEGRAL	0,68	0,61	0,56	0,50
	Total morto (< 0,7 cm)	NDVI; VARI; Vlgreen; SIPI; SAVI; MSI; INTEGRAL; EVI	0,70	0,60	0,73	0,64
	Total (vivo e morto)	NDVI; VARI; Vlgreen; SIPI; SAVI; NBR; INTEGRAL; DER23	0,79	0,72	0,94	0,82
3	Herbáceo morto	VARI; Vlgreen; NDWI; NDII6; NBR; MSR; INTEGRAL; GVMI; DER56	0,77	0,73	0,35	0,29
	Lenhoso morto de 1-h	SR; SIPI; SAVI; NDWI; NBR; MSR; MSI; MNDWI; GVMI; EVI	0,56	0,48	0,63	0,49
	Total morto (< 0,7 cm)	VARI; Vlgreen; SR; SIPI; NDII6; NBR; INTEGRAL; GVMI; EVI; DER56	0,70	0,65	0,83	0,67
	Total (vivo e morto)	NDVI; VARI; Vlgreen; SR; SIPI; SAVI; NDII6; NBR; MSR; GVMI; EVI; DER56; DER45	0,57	0,46	1,26	1,07

FONTE: O Autor (2024).

NOTA: Per = Período da estação seca, onde: (1) Início da estação seca (maio e junho); (2) Final da estação seca (agosto e setembro); (3) Toda estação seca (maio a setembro).

Para todo o período da estação seca a equação que melhor se desempenhou foi para a estimativa de HM, com R^2 de 0,77, e em seguida a equação para estimativa de M07 com R^2 de 0,70 ($p < 0,05$). Destaca-se que para a estimativa de Tot07 em todo o período da estação seca, os valores de R^2 validados decrescem para 0,57 em relação aos períodos inicial ($R^2 = 0,78$) e final ($R^2_{aj} = 0,79$).

Tanto nas equações não validadas quanto nas validadas, as equações para a estimativa de combustível herbáceo seco e combustível total morto com diâmetro inferior a 0,7 cm foram as que melhor se desempenharam quanto aos seus respectivos valores de coeficiente de determinação (R^2) em relação às demais variáveis. Quanto aos valores do RMSE e MAE, ressalta-se que, salvo algumas exceções, tais valores seguem uma relação inversa com os valores de R^2 e R^2_{aj} .

4.1.4 Ajustes em função de todas as variáveis independentes

A Tabela 5 apresenta as métricas das equações de regressão linear múltipla, que foram validadas considerando as variáveis independentes do estudo. As equações de regressão linear múltipla tiveram melhor desempenho com os ajustes pelo método *stepwise*. A Tabela 5 apresenta as métricas das equações ajustadas por este método. As equações validadas pelo método de validação cruzada *k-fold cross validation*, que se destacaram quanto ao coeficiente de determinação (R^2), foram para a estimativa do combustível morto total < 0,7 cm de diâmetro (M07), com $R^2 = 0,92$, e combustível herbáceo morto (HM), com $R^2 = 0,89$. Estas equações mencionadas anteriormente são para o início da estação seca ($p < 0,05$). Entretanto, os menores valores de RMSE e MAE foram observados para estimativas de combustível herbáceo morto no início da estação seca, com valores abaixo de 0,40. As métricas estatísticas verificadas para o final do período seco foram inferiores às observadas para as equações ajustadas para o início do período seco na área de estudo.

TABELA 6 - MÉTRICAS ESTATÍSTICAS DA VALIDAÇÃO CRUZADA REALIZADA PARA OS MELHORES AJUSTES FEITOS PARA A ESTIMATIVA DE CARGA ATRAVÉS DE TODAS AS VARIÁVEIS INDEPENDENTES DO ESTUDO

Per	Combustível estimado (y)	Variáveis predictoras (x)	R ²	R ² _{aj}	RMSE	MAE
1	Herbáceo morto	FVS; Solo; B5: nir; B6: swir 1; B7: swir 2; VARI; SR; SIPI; NDII; MSR; MSI; GVMI; DER56; DER34;	0,89	0,81	0,37	0,32
	Lenhoso morto de 1-h	FVS; Solo; GV; B4: red; B5: nir; B6: swir 1; B7: swir 2; NDVI; VARI; Vlgreen; SR; SIPI; SAVI; NDWI; NRR; MSI; MNDWI; DER34; DER23;	0,81	0,55	0,45	0,37
	Total morto (< 0,7 cm)	FVS; Solo; GV; B4: red; B5: nir; B6: swir 1; B7: swir 2; VARI; Vlgreen; SR; SIPI; SAVI; NDWI; NDII6; NBR; DER45;	0,92	0,84	0,49	0,40
	Total (vivo e morto)	FVS; Solo; B2: blue; B4: red; B5: nir; B6: swir 1; NDVI; VARI; Vlgreen; SR; SIPI; SAVI; NDWI; NDII6; NBR; MSR; MSI; MNDWI; INTEGRAL; DER45; DER34; DER23; GVMI;	0,81	0,37	1,26	1,06
2	Herbáceo morto	FVS; Solo; B2: blue; B3: green; B5: nir; B6: swir 1; B7: swir 2; NDVI; Vlgreen; SR; NDWI; NDII6; NBR; MSR; MSI; MNDWI; GVMI; EVI; DER56; DER34; DER23;	0,81	0,47	0,44	0,38
	Lenhoso morto de 1-h	FVS; Solo; GV; B2: blue; B3: green; B4: red; B5: nir; B7: swir 2; NDVI; VARI; Vlgreen; SR; SIPI; SAVI; NDWI; NDII6; NRR; MSR; MSI; INTEGRAL; GVMI; EVI; DER56; DER45; DER34; DER23;	0,45	1,59	1,90	1,53
	Total morto (< 0,7 cm)	Solo; GV; B2: blue; B3: green; B4: red; B5: nir; B6: swir 1; B7: swir 2; NDVI; VARI; Vlgreen; SR; SIPI; SAVI; NDWI; NDII6; NBR; MSR; MSI; INTEGRAL; GVMI; EVI; DER56; DER45; DER34; DER23	0,64	0,72	2,24	1,98
	Total (vivo e morto)	Solo; GV; B2: blue; B3: green; B4: red; B5: nir; B6: swir 1; B7: swir 2; NDVI; VARI; Vlgreen; SR; SAVI; NDWI; NDII6; MSR; MSI; INTEGRAL; EVI; DER56; DER45; DER34; DER23;	0,56	0,44	2,27	2,01
3	Herbáceo morto	Solo; B3: green; B4: red; B5: nir; B6: swir 1; VARI; Vlgreen; SR; SAVI; NDWI; NDII6; MSR; INTEGRAL; GVMI; EVI; DER56;	0,78	0,72	0,36	0,31
	Lenhoso morto de 1-h	FVS; Solo; B2: blue; B4: red; B7: swir 2; VARI; SR; SIPI; NDWI; NRR; MSI; INTEGRAL; GVMI; EVI; DER45;	0,57	0,45	0,62	0,51
	Total morto (< 0,7 cm)	FVS; Solo; B7: swir 2; VARI; Vlgreen; SIPI; NBR; MSR; MSI; INTEGRAL; GVMI; EVI; DER45;	0,73	0,66	0,75	0,62
	Total (vivo e morto)	FVS; Solo; GV; B2: blue; B4: red; B5: nir; B6: swir 1; B7: swir 2; VARI; SIPI; NDWI; NBR; DER56; DER34;	0,63	0,54	1,06	0,91

FONTE: O Autor (2024).

NOTA: Per = Período da estação seca, onde: (1) Início da estação seca (maio e junho); (2) Final da estação seca (agosto e setembro); (3) Toda estação seca (maio a setembro).

Para todo o período da estação seca, os valores de R² variaram de 0,57 a 0,78. A equação para estimativa do combustível HM teve o melhor desempenho, com R² = 0,78, seguida pela equação *stepwise* para calcular o combustível morto total <

0,7 cm de diâmetro (herbáceo morto + lenhoso morto de 1-h), com $R^2 = 0,73$ ($p < 0,05$). Os valores de R^2_{aj} das equações submetidas à validação cruzada podem ser negativos sem limite inferior e apresentar valor máximo um, conforme observado por Peterson; Roberts e Dennison (2008), o que foi o caso das equações no final da estação seca. Os valores mais baixos de RMSE e MAE foram encontrados para estimar o combustível de HM.

4.2 ESTIMATIVAS UTILIZANDO O ALGORITMO *RANDOM FOREST*

4.2.1 Métricas de performance dos modelos

Para utilização do algoritmo *Random Forest*, todo o período seco foi considerado para o ajuste dos modelos. Os modelos não foram divididos para início e final da estação seca, como foi feito nas análises de regressão linear múltipla. Assim como as equações de regressão, o algoritmo *Random Forest* foi ajustado para cada variável estimada considerando todas as variáveis independentes do estudo e as variáveis selecionadas pelo método *stepwise*.

Diferentemente das equações de regressão linear múltipla, os modelos *Random Forest* apresentaram ligeira vantagem nos ajustes com todas as variáveis independentes em comparação aos ajustes com as variáveis selecionadas pelo método *stepwise*, conforme mostrado na Tabela 6. Os valores de R^2 dos modelos do algoritmo *Random Forest* variaram de 0,52 a 0,83; os valores mais altos foram encontrados para estimar o combustível HM e o combustível morto total < 0,7 cm de diâmetro (herbáceo morto + lenhoso morto de 1-h).

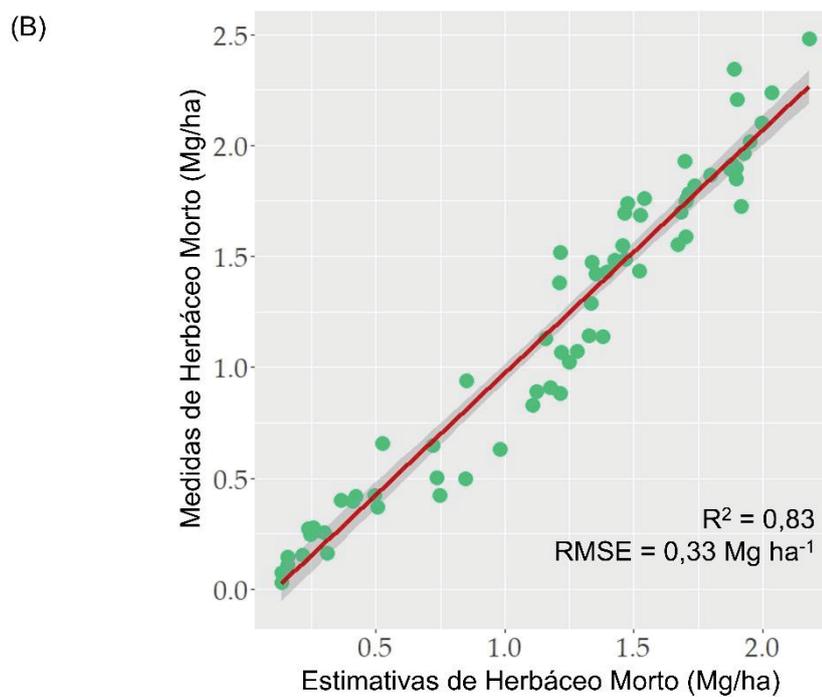
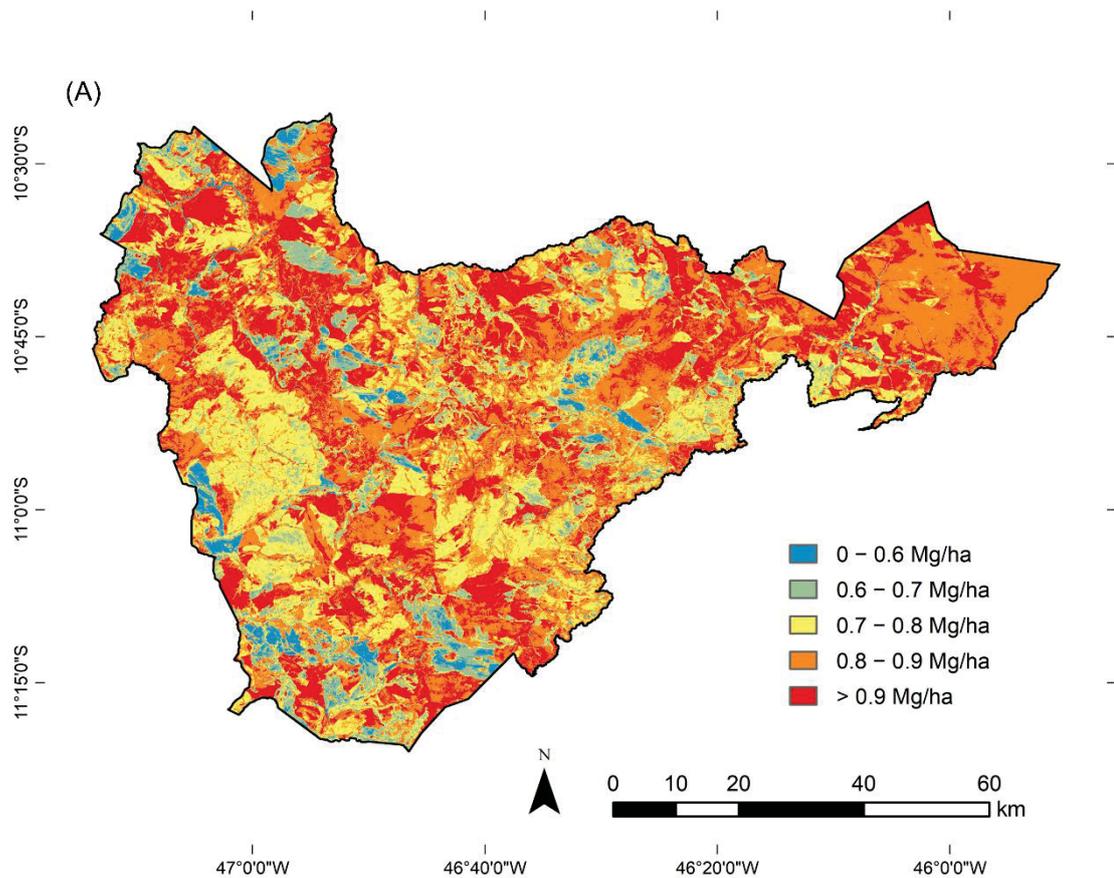
TABELA 7 - MÉTRICAS ESTATÍSTICAS PARA AVALIAÇÃO DOS MODELOS GERADOS PELO ALGORITMO *RANDOM FOREST*

Combustível estimado (y)	Variáveis predictoras (x)	R ²	R ² adj	RMSE	MAE
Herbáceo morto	Todas as variáveis predictoras	0,83	0,71	0,33	0,24
	* Solo; B3: green; B4: red; B5: nir; B6: swir 1; VARI; Vlgreen; SR; SAVI; NDWI; NDII6; MSR; INTEGRAL; GVMI; EVI; DER56	0,83	0,78	0,33	0,23
Lenhoso morto de 1-h	Todas as variáveis predictoras	0,59	0,30	0,58	0,44
	* FVS; Solo; B2: blue; B4: red; B7: swir 2; VARI; SR; SIPI; NDWI; NRR; MSI; INTEGRAL; GVMI; EVI; DER45	0,52	0,38	0,61	0,46
Total morto (< 0,7 cm)	Todas as variáveis predictoras	0,83	0,71	0,59	0,44
	* FVS; Solo; B7: swir 2; VARI; Vlgreen; SIPI; NBR; MSR; MSI; INTEGRAL; GVMI; EVI; DER45	0,79	0,74	0,63	0,49
Total (vivo e morto)	Todas as variáveis predictoras	0,62	0,35	0,89	0,75
	* FVS; Solo; GV; B2: blue; B4: red; B5: nir; B6: swir 1; B7: swir 2; VARI; SIPI; NDWI; NBR; DER56; DER34	0,55	0,43	0,96	0,81

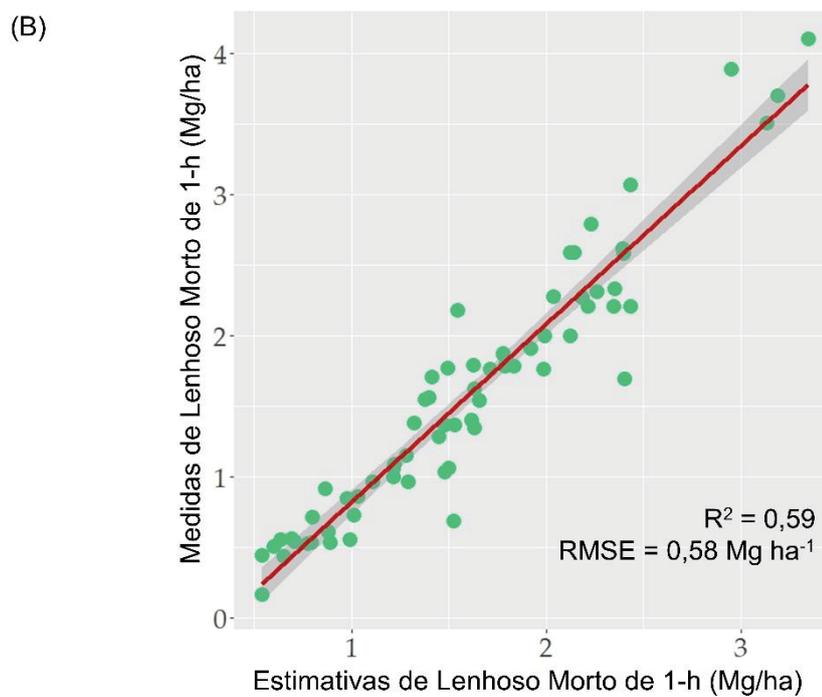
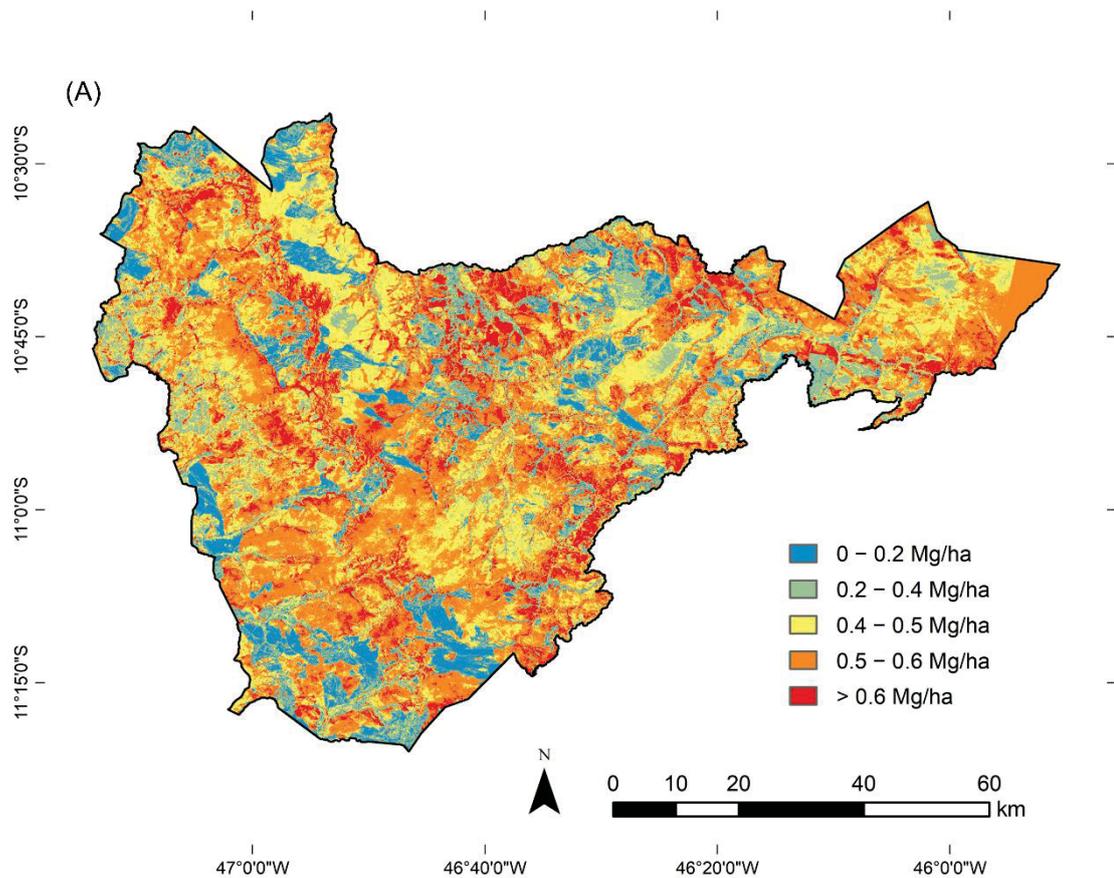
FONTE: O Autor (2024).

NOTA: * Variáveis selecionadas utilizando o método *stepwise* nas análises de regressão linear múltiplas.

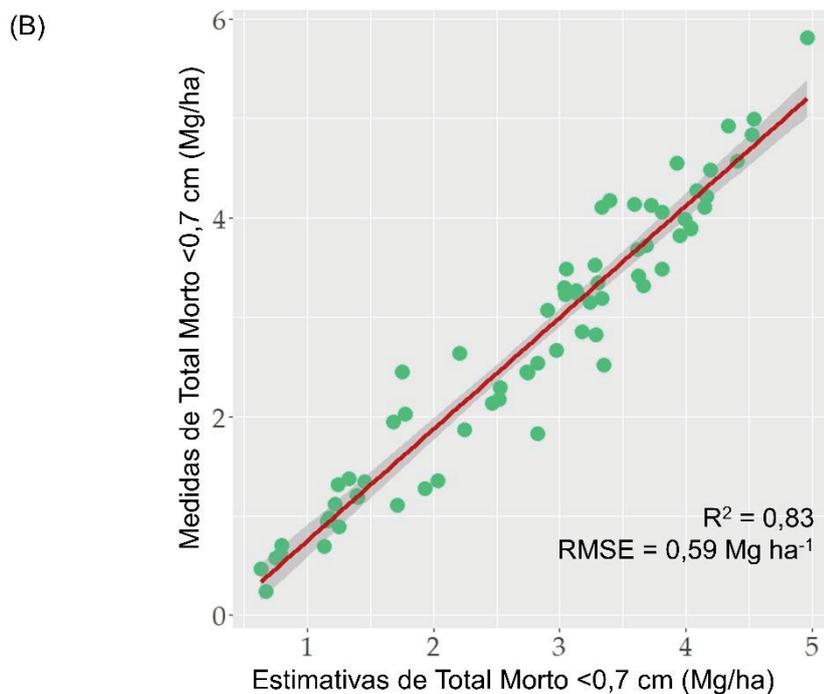
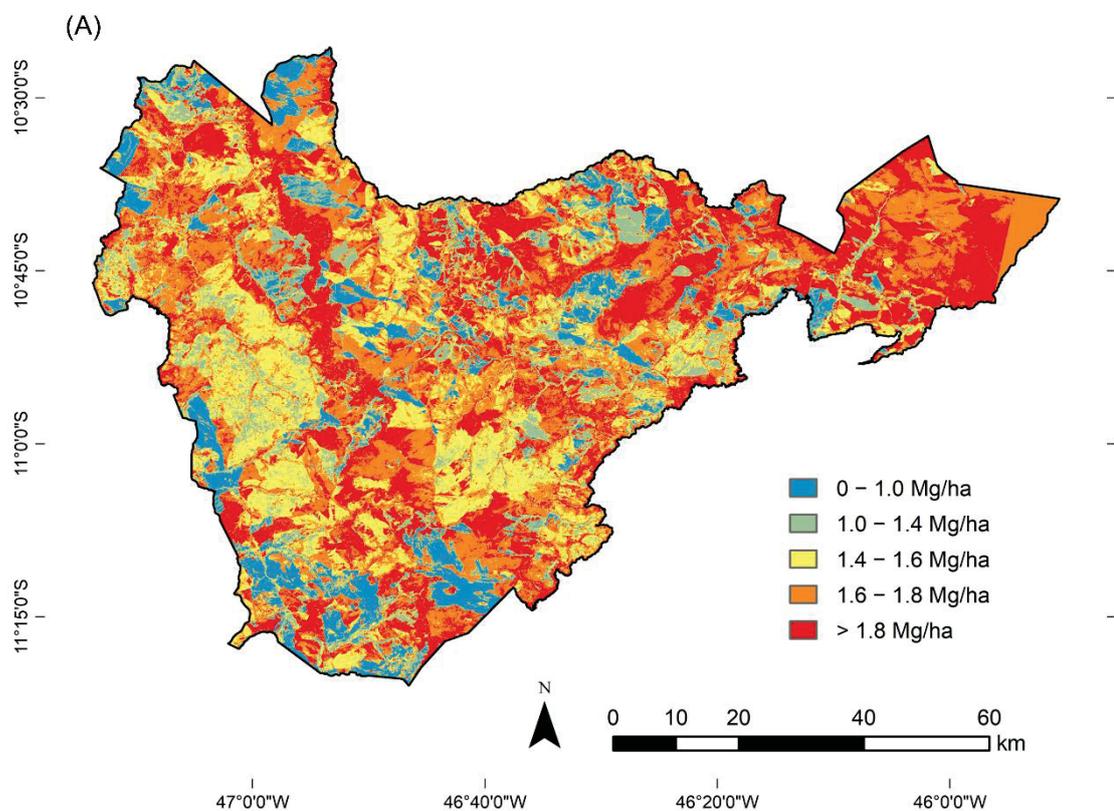
Para estimativa do combustível fino total (vivo e morto), o melhor desempenho foi relacionado ao modelo utilizando todas as variáveis independentes, com $R^2 = 0,62$. Para os valores de RMSE e MAE das estimativas utilizando o algoritmo *Random Forest*, os valores mais baixos foram registrados para a estimativa de combustível HM, com 0,33 e 0,23, respectivamente. Em contrapartida, os maiores valores de RMSE e MAE corresponderam à estimativa da carga total de combustível fino (vivo e morto). As Figuras 10 a 13 apresentam os mapeamentos de carga de combustível superficial na Estação Ecológica Serra Geral do Tocantins, com os melhores ajustes, utilizando o modelo *Random Forest*, para cada categoria de carga de combustível analisada (herbáceo morto; lenhoso morto de 1-h; total morto < 0,7 cm e; total < 0,7 cm vivo e morto, respectivamente).

FIGURA 10 - MAPEAMENTO DE CARGA DE COMBUSTÍVEL UTILIZANDO O MELHOR MODELO *RANDOM FOREST* PARA COMBUSTÍVEL HERBÁCEO MORTO

FONTE: O Autor (2024).

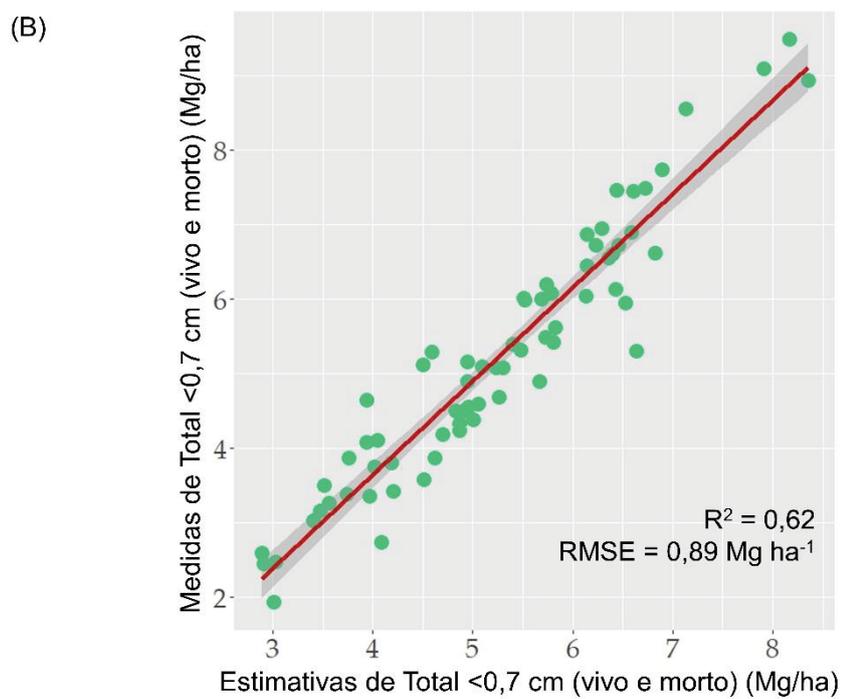
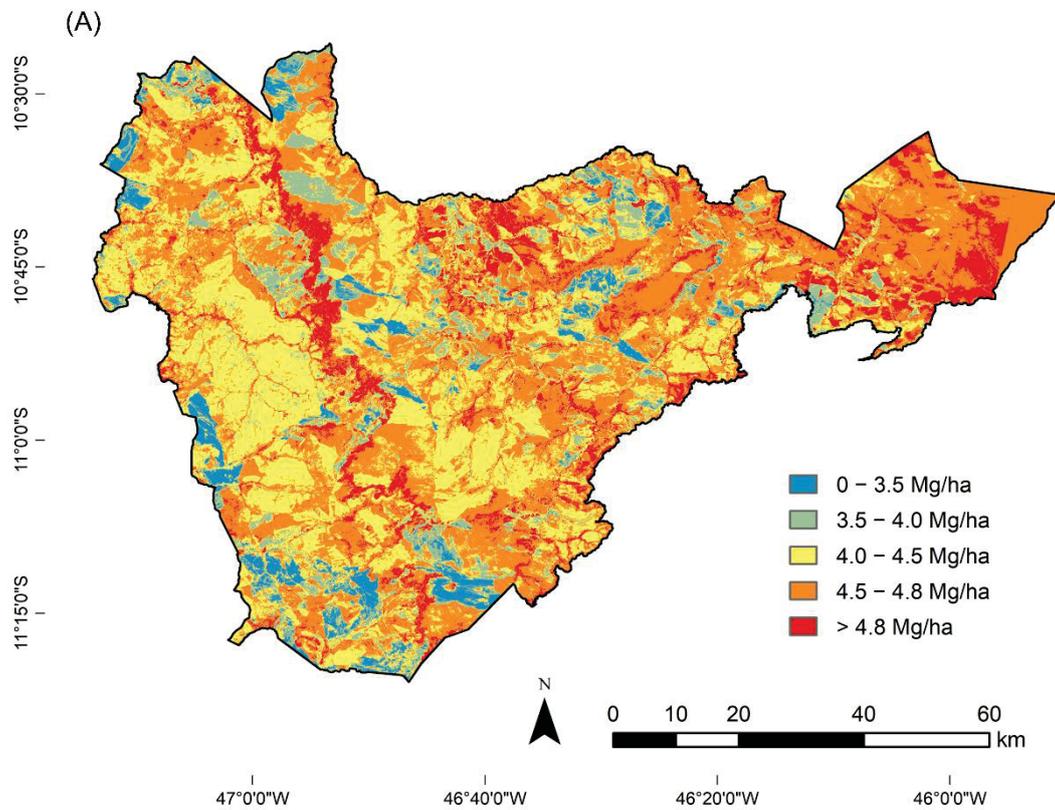
FIGURA 11 - MAPEAMENTO DE CARGA DE COMBUSTÍVEL UTILIZANDO OS MELHORES MODELOS *RANDOM FOREST* PARA COMBUSTÍVEL LENHOSO MORTO DE 1-H

FONTE: O Autor (2024).

FIGURA 12 - MAPEAMENTO DE CARGA DE COMBUSTÍVEL UTILIZANDO OS MELHORES MODELOS *RANDOM FOREST* PARA COMBUSTÍVEL TOTAL MORTO < 0,7 CM

FONTE: O Autor (2024).

FIGURA 13 - MAPEAMENTO DE CARGA DE COMBUSTÍVEL UTILIZANDO OS MELHORES MODELOS *RANDOM FOREST* PARA COMBUSTÍVEL TOTAL < 0,7 CM (VIVO E MORTO)



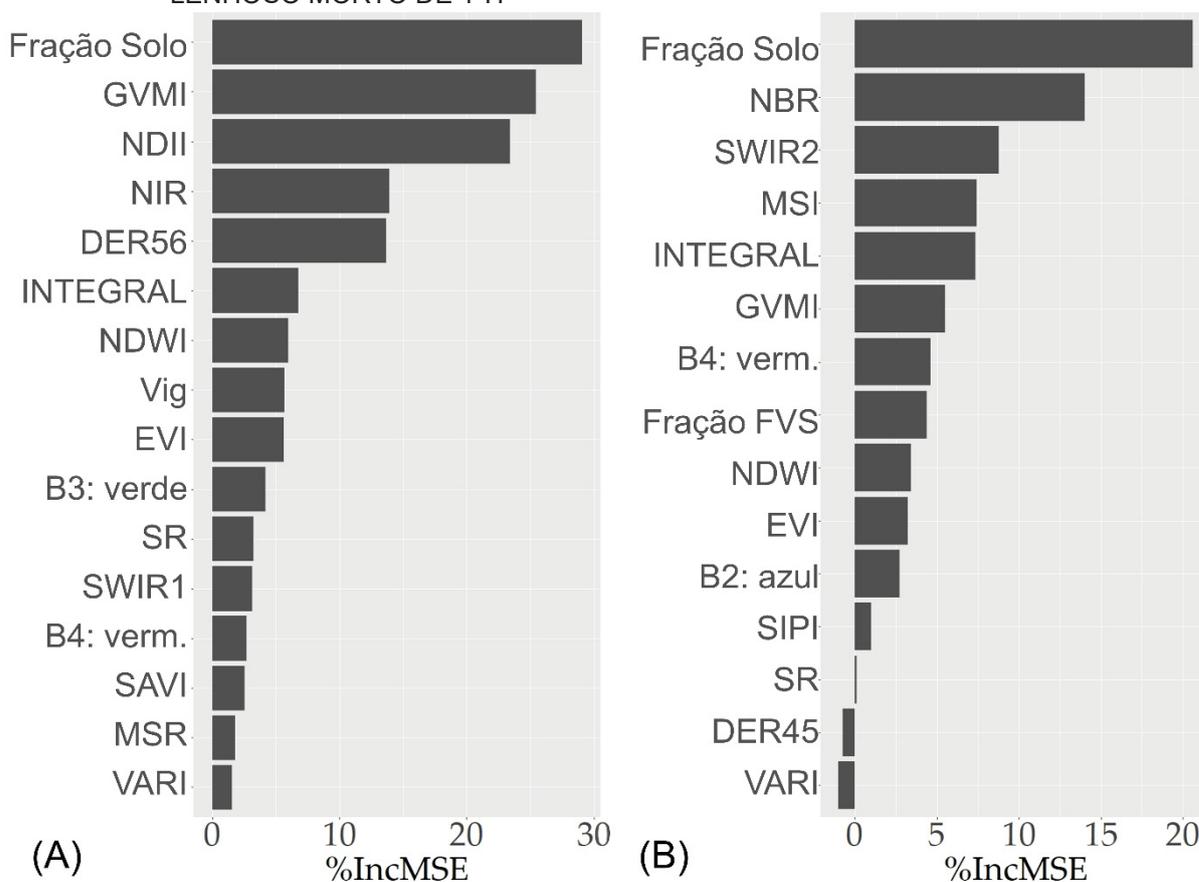
FONTE: O Autor (2024).

4.2.2 Importância das variáveis nos modelos *Random Forest*

Nas Figuras 14 e 15 são apresentadas a importância das variáveis dos modelos de melhor desempenho ajustados através do algoritmo *Random Forest* (RF). Analisando os resultados da importância das variáveis nos modelos RF apresentados nas Figuras 14 e 15, cabe ser destacado a considerável relevância da variável fração solo (FS) em todos os modelos abordados. A variável FS obteve incremento no erro quadrado médio (% IncMSE) maior que 20% em todos os modelos apresentados. Isso significa que, com a retirada da variável preditora FS, ocorre um incremento no erro quadrado médio superior a 20% nas estimativas de carga de combustível para as quatro classes analisadas. Entre as variáveis de combustível, nas quais o FS exerceu maior efeito, destacaram-se o combustível morto total < 0,7 cm de diâmetro (herbáceo morto + lenhoso morto de 1-h) e o combustível herbáceo morto, apresentando valores de 33,5% e 29,1%, respectivamente.

Os índices de vegetação NDII, NBR, GVMi e DER56 apresentaram-se como as segundas variáveis de maior importância considerando as estimativas de combustível herbáceo morto, lenhoso morto de 1-h, combustível morto total < 0,7 cm de diâmetro (herbáceo morto + lenhoso morto de 1-h) e combustível fino total (vivo e morto), respectivamente. O GVMi apareceu com maior frequência entre os índices de vegetação e foi mais importante nos modelos *Random Forest* ajustados. Em relação à refletância das bandas, o canal infravermelho de ondas curtas (SWIR2 - 2,11–2,29 μm) ocorreu com mais frequência e teve a importância mais significativa. A Figura 14 ilustra graficamente a importância dos modelos do algoritmo *Random Forest* com melhores ajustes para combustível herbáceo morto e lenhoso morto de 1-h.

FIGURA 14 - IMPORTÂNCIA DAS VARIÁVEIS DO MODELO DO ALGORITMO *RANDOM FOREST* COM MELHOR AJUSTE PARA ESTIMATIVA DE CARGA DE HERBÁCEO MORTO E LENHOSO MORTO DE 1-H

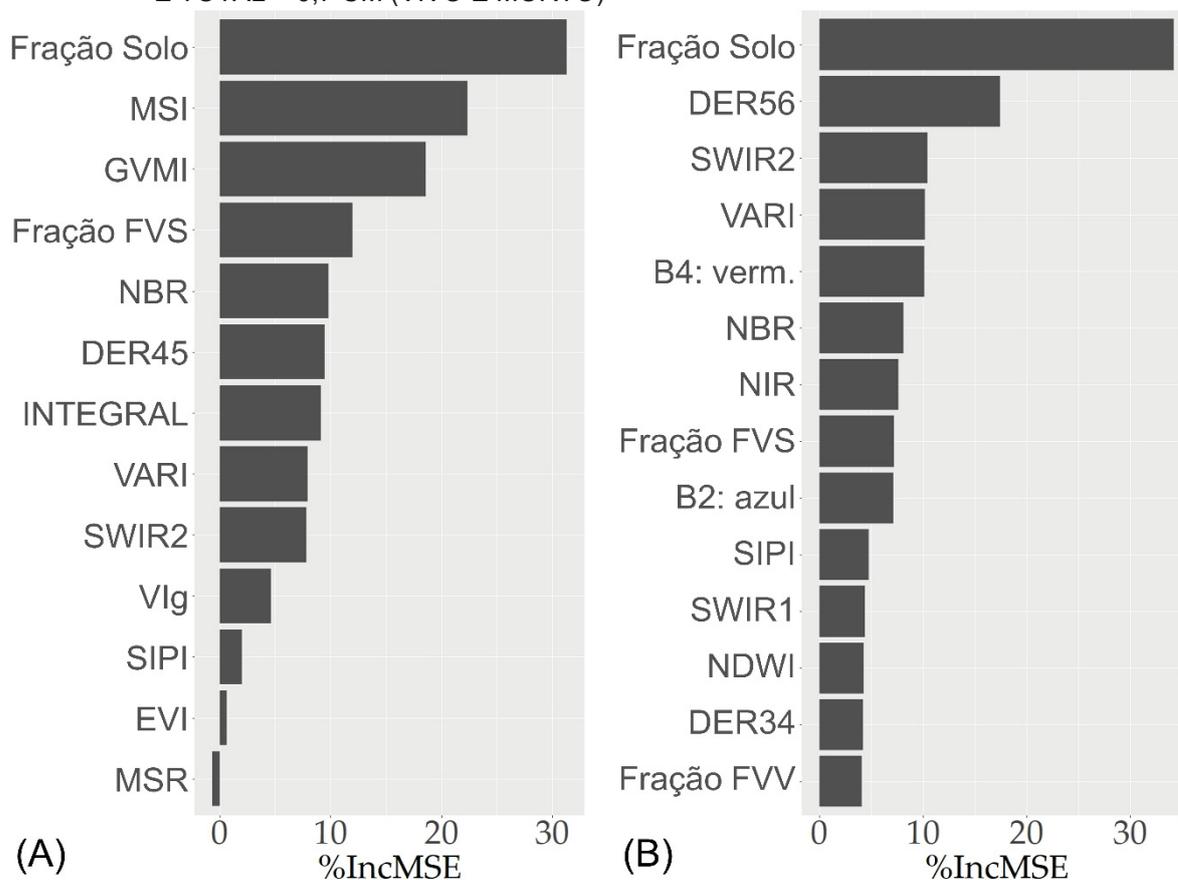


FONTE: O Autor (2024).

NOTA: (A) Modelo RF para combustível herbáceo morto (HM) e; (B) Modelo RF para combustível lenhoso morto de 1-h (LM1). % IncMSE indica o aumento do Erro Quadrático Médio em porcentagem.

Na Figura 15 é apresentado o comportamento gráfico dos valores de importância dos modelos de melhor desempenho do algoritmo *Random Forest* para combustível total morto < 0,7 cm e total < 0,7 cm (vivo e morto).

FIGURA 15 - IMPORTÂNCIA DAS VARIÁVEIS DO MODELO DO ALGORITMO *RANDOM FOREST* COM MELHOR AJUSTE PARA ESTIMATIVA DE CARGA DE TOTAL MORTO < 0,7 CM E TOTAL < 0,7 CM (VIVO E MORTO)



FONTE: O Autor (2024).

NOTA: (A) Modelo RF para combustível morto total < 0,7 cm (M07) e; (B) Modelo RF para combustível fino total (vivo e morto). % IncMSE indica o aumento do Erro Quadrático Médio em porcentagem.

4.2 ESTIMATIVAS UTILIZANDO O ALGORITMO *K-NEAREST NEIGHBOR*

Da mesma forma, os dados do mesmo banco de dados utilizado para a aplicação do algoritmo RF foram executados com o algoritmo *k-Nearest Neighbor* (k-NN), de modo que foram construídos dois modelos para cada variável de carga de combustível: um modelo considerando todas as variáveis independentes de estudo e outro modelo considerando as variáveis selecionadas pelo método *stepwise*. Como parâmetro para utilização do algoritmo k-NN, os valores de K foram escolhidos com base nos menores valores de RMSE, variando de 5 a 13. A Tabela 7 demonstra os valores de K escolhidos para cada modelo de algoritmo de k-vizinhos mais próximos.

TABELA 8 - VALORES DE K ESCOLHIDOS PARA CADA MODELO DO ALGORITMO K-NN

Combustível estimado (y)	Variáveis preditoras (x)	RMSE	Valor K escolhido
Herbáceo morto	Todas as variáveis preditoras	0,4072	5
	<i>Stepwise</i> *	0,4453	7
Lenhoso morto de 1-h	Todas as variáveis preditoras	0,8183	7
	<i>Stepwise</i> *	0,8253	9
Total morto (< 0,7 cm)	Todas as variáveis preditoras	1,1051	5
	<i>Stepwise</i> *	1,1233	9
Total (vivo e morto)	Todas as variáveis preditoras	1,6060	7
	<i>Stepwise</i> *	1,6136	13

FONTE: O Autor (2024).

NOTA: * Variáveis selecionadas utilizando o método de *stepwise* nas análises de regressão linear múltiplas.

Assim como os modelos *Random Forest*, os modelos k-NN apresentaram desempenhos ligeiramente superiores para os ajustes feitos com todas as variáveis preditoras do estudo em comparação com os modelos que tiveram variáveis selecionadas pelo método *stepwise*. Os valores de R^2 variaram de 0,30 a 0,68 e os modelos k-NN com melhor ajuste foram aqueles para estimativa do combustível de HM, seguido do modelo para estimativa do combustível morto total < 0,7 cm, com $R^2 = 0,54$. A Tabela 8 fornece as métricas estatísticas dos modelos de algoritmo k-NN.

TABELA 9 - MÉTRICAS ESTATÍSTICAS PARA AVALIAÇÃO DOS MODELOS GERADOS PELO ALGORITMO K-NN

Combustível estimado (y)	Variáveis preditoras (x)	R^2	R^2_{adj}	RMSE	MAE
Herbáceo morto	Todas as variáveis preditoras	0,68	0,45	0,37	0,30
	<i>Stepwise</i> *	0,61	0,49	0,41	0,34
Lenhoso morto de 1-h	Todas as variáveis preditoras	0,34	-0,13	0,74	0,61
	<i>Stepwise</i> *	0,31	0,11	0,76	0,63
Total morto (< 0,7 cm)	Todas as variáveis preditoras	0,54	0,21	0,92	0,78
	<i>Stepwise</i> *	0,49	0,37	0,98	0,84
Total (vivo e morto)	Todas as variáveis preditoras	0,38	-0,07	1,43	1,23
	<i>Stepwise</i> *	0,30	0,12	1,53	1,31

FONTE: O Autor (2024).

NOTA: * Variáveis selecionadas pelo método *stepwise* nas análises de regressão linear múltiplas.

Em relação aos valores de RMSE e MAE, as estimativas utilizando o algoritmo k-NN apresentaram os menores valores para a estimativa do combustível herbáceo morto, como 0,37 e 0,30, respectivamente. Os maiores valores de RMSE e MAE com os modelos k-NN foram encontrados para estimar a carga total de combustível fino (vivo e morto) (Tabela 8).

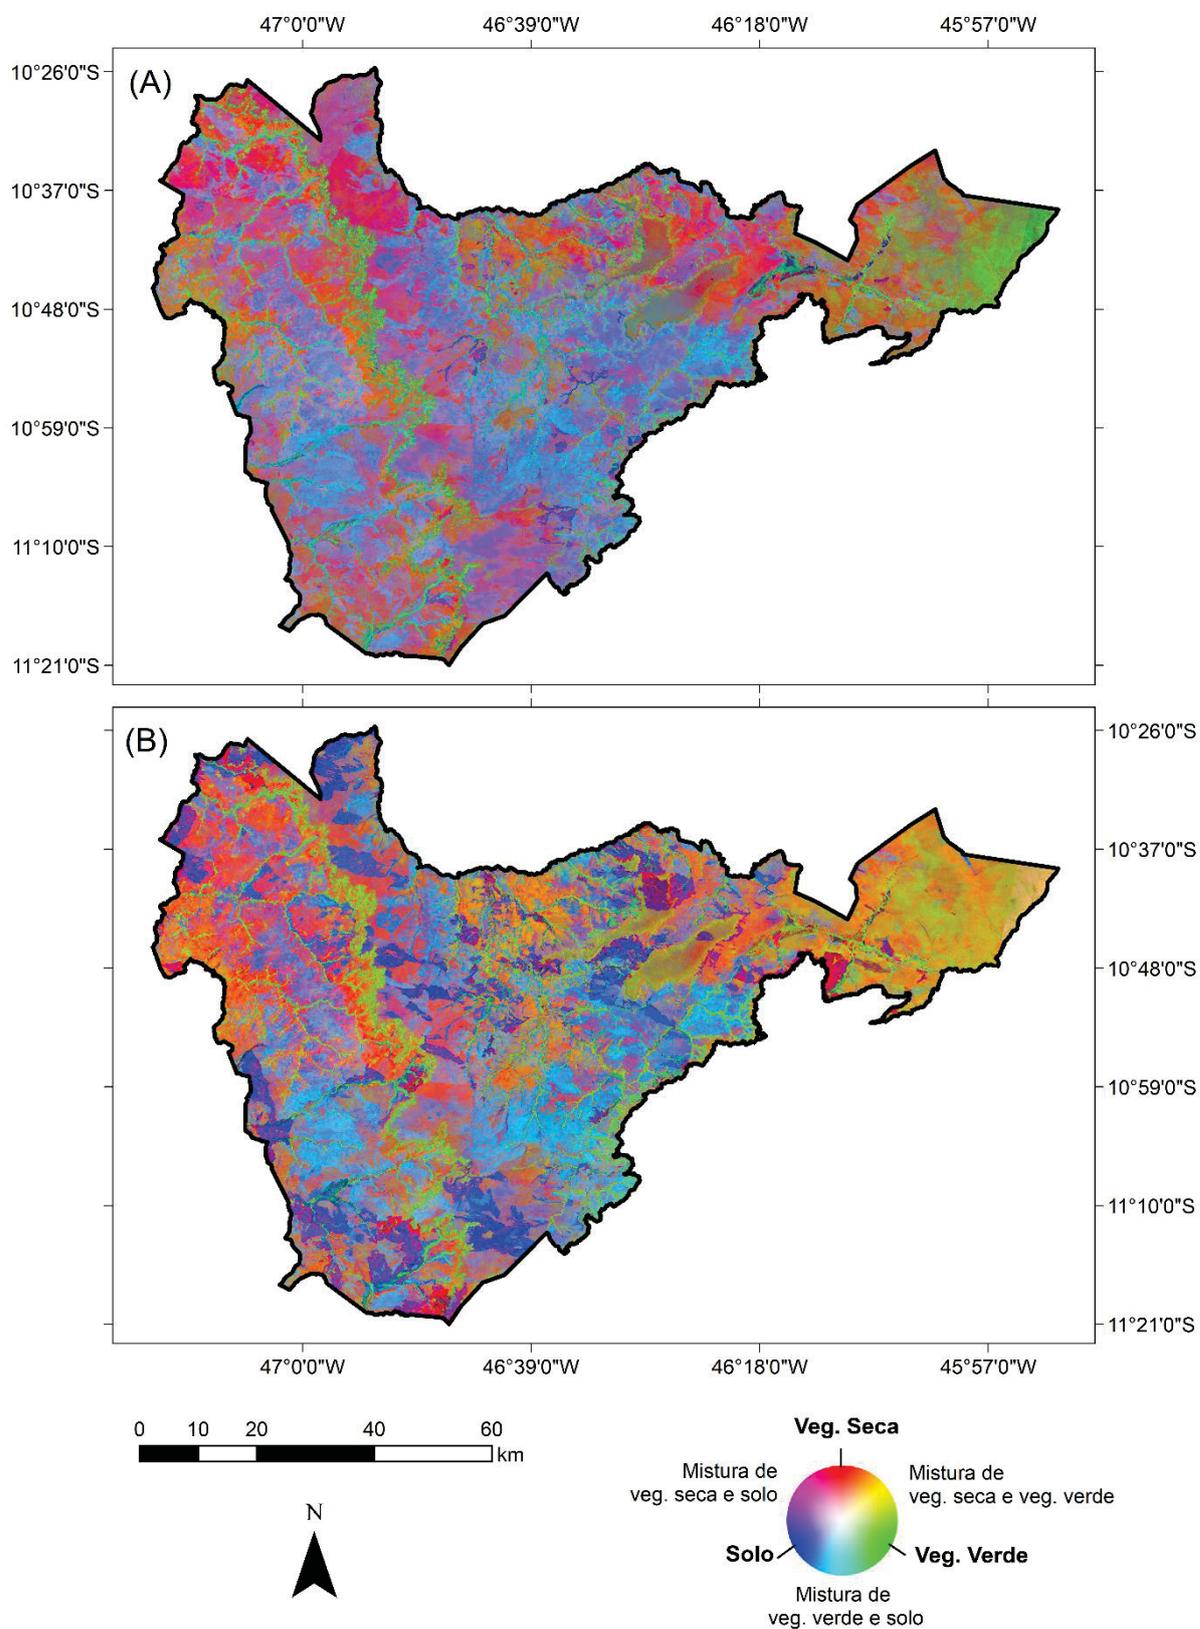
5 DISCUSSÃO

Dadas as baixas correlações das classes de combustíveis vivos (herbáceo vivo e arbustivo), as análises estatísticas para a sua estimativa não puderam ser realizadas. Porém, de acordo com os resultados obtidos por Santos et al. (2018), o baixo nível de umidade das espécies campestres do Cerrado é o principal fator para o aumento da inflamabilidade do combustível. Além disso, a proporção de combustível morto fino sobre a proporção de combustível vivo durante a estação seca no bioma pode chegar a 70%, ou superior a 80%, considerando o combustível herbáceo da área, com base na caracterização do combustível de Santos et al. (2020).

Além disso, a espessura fina dos combustíveis herbáceos em estado fisiologicamente inativo (e.g. herbáceo e lenhoso morto de 1-h) torna o teor de umidade desses combustíveis mais sensíveis a mudanças nas condições atmosféricas, afetando assim sua capacidade de ignição e deixando áreas com predominância desses tipos de combustíveis mais propensas à ocorrência de incêndios florestais, principalmente na estação seca (CAWSON et al., 2020). Conforme relatado por Slijepcevic et al. (2015) e Soares; Batista; Tetto (2017), a baixa umidade do combustível é um dos principais fatores que contribuem para a ocorrência de grandes incêndios.

Dos ajustes das equações de regressão linear múltipla para início e final do período seco no bioma Cerrado, as equações ajustadas para início do período seco tiveram melhor desempenho estatístico. Isso pode ser explicado pela análise dos resultados obtidos por Santos et al. (2020), que caracterizou o combustível da vegetação campestre do Cerrado. Neste estudo, características do combustível, como a quantidade de indivíduos, o número de espécies, a altura das herbáceas e a carga de combustível nas diferentes classes (*timelag*) apresentam comportamentos diferentes entre o primeiro e o último mês da estação seca na fitofisionomia analisada. O mapeamento da condição do combustível mostrando frações de vegetação seca (FVS), vegetação verde (FVV) e solo (FS) para o início da estação seca (maio) em contraste com a condição do combustível no final da estação seca (setembro) é apresentado nas Figuras 16A e 16B, respectivamente.

FIGURA 16 - MAPEAMENTO DA CONDIÇÃO FISIOLÓGICA DO COMBUSTÍVEL CONSTITUÍDO POR TRÊS IMAGENS FRAÇÃO DE *SUBPIXEL* (R: FVS; G: FVV; B: SOLO) NA ESTAÇÃO ECOLÓGICA SERRA GERAL DO TOCANTINS



FONTE: O Autor (2024).

NOTA: (A) Início da estação seca (maio) e; (B) Final da estação seca (setembro).

Por exemplo, dadas as diferentes idades dos combustíveis presentes na área, os valores de carga de combustível herbáceo morto nos primeiros meses da estação seca (maio e junho) mostraram uma diferença estatisticamente significativa no combustível herbáceo morto entre as idades de um e quatro anos. No final da estação seca (agosto e setembro), não foi encontrada diferença estatisticamente significativa entre carga de herbáceo morto entre as idades de dois a quatro anos sem queima ($p < 0,05$).

Considerando todos os ajustes das equações de regressão linear múltipla do estudo (início, final e todo o período seco), os valores de R^2 variaram de 0,45 a 0,92. Para todo o período seco, o maior valor foi de 0,78 para a equação ajustada para estimativa de combustível herbáceo morto (Tabela 5). Resultados semelhantes foram relatados por Tucker (1977), que apresentou valores mais expressivos considerando os valores do coeficiente de determinação (R^2), utilizando a faixa de 0,385 μm do espectro eletromagnético como variável preditora para estimar a biomassa seca total ($R^2 = 0,80$). Trabalhando com imagens Landsat 8 OLI para estimativa de carga de combustível em tipologia *Hulunbuir Grassland*, Bao et al. (2022) obtiveram valores de $R^2 = 0,64$, utilizando modelos baseados em regressão linear múltipla. Usando imagens Landsat 5 TM para estimar a biomassa acima do solo no interior do Alasca, Ji et al. (2012) obtiveram valor de R^2 de 0,73 em seu modelo de regressão. Em um dos poucos estudos realizados no Cerrado, Franke et al. (2018) encontraram relações entre variáveis obtidas a partir de análises de mistura espectral e a biomassa de combustíveis superficiais finos em seu modelo de regressão, com valores de R^2 de 0,81 (fração de vegetação seca não fotossintética - FNPV) e 0,65 (fração solo - FS).

Os resultados de Franke et al. (2018) diferem dos obtidos no presente estudo: entre as variáveis obtidas através da análise de mistura espectral e a carga de combustível, as relações mais significativas foram encontradas para os valores de fração solo (FS). Porém, os modelos de regressão linear ajustados por Franke et al. (2018) não consideraram uma análise de validação cruzada. É possível, portanto, constatar que existem poucos estudos que envolvam a estimativa de combustível superficial a partir de imagens de satélite, especialmente para o bioma Cerrado.

Assim como os ajustes das equações de regressão linear múltipla, os modelos resultantes da aplicação do algoritmo *Random Forest* com melhor desempenho com base nas métricas de avaliação foram para estimar as classes de combustível herbáceo morto e a classe de combustível morto total $< 0,7$ cm (herbáceo + lenhoso

morto de 1-h). Tais variáveis apresentaram valores superiores às demais classes, atingindo $R^2 = 0,83$. As métricas estatísticas obtidas para estimar a carga de combustível lenhoso morto de 1-h demonstraram menor desempenho em relação às demais variáveis (Tabela 6). Isto pode ser explicado pela menor continuidade espacial em comparação com o combustível herbáceo morto presente na área de estudo. Dube e Mutanga (2015) utilizaram imagens Landsat 8 OLI e 7 ETM+, tendo a reflectância das bandas e índices de vegetação como variáveis preditoras. Os referidos autores testaram o algoritmo *Random Forest* para estimar a biomassa acima do solo na África do Sul e encontraram valores de coeficiente de determinação (R^2) variando de 0,43 a 0,65.

O estudo de Pierce, Farris e Taylor (2012) utilizou o algoritmo RF e informações do Landsat 5 TM, dados de campo e fatores topográficos para modelagem e mapeamento de combustíveis de dossel na Califórnia (EUA) e obtiveram valores de pseudo- R^2 variando de 0,55 a 0,68. Frazier et al. (2014) caracterizaram a biomassa acima do solo em uma floresta boreal usando métricas de segmentação temporal Landsat e encontraram valores de $R^2 = 0,62$ estimados por modelos *Random Forest*. Gao et al. (2020) encontraram valores de R^2 mais elevados (0,75) usando dados do sensor MODIS para estimar a biomassa acima do solo em uma região asiática.

Quanto à importância das variáveis dos modelos RF com melhor ajuste, para as classes de combustíveis mortos (herbáceo morto, lenhoso morto de 1-h e combustíveis mortos totais < 0,7 cm) e combustíveis finos totais (vivos e mortos), a fração solo (FS) da análise de mistura espectral (SMA) foi a variável independente que exerceu importância mais significativa. Esses resultados demonstram maiores correlações entre a variável FS e as variáveis obtidas na análise de mistura espectral. A fitofisionomia de Cerrado campestre é predominantemente aberta (campo limpo e campo sujo) e possui uma população esparsa de espécies arbóreas. Dada a idade do combustível e o seu nível de cobertura, a maior ou menor exposição do solo torna-se bastante perceptível na resposta da análise da mistura espectral, que demonstrou uma relação inversa com a carga superficial de combustível.

Apesar da importância da variável FS nos modelos *Random Forest*, não há conhecimento do seu desempenho em áreas com maior presença de espécies arbóreas. Pelo menos cinco índices de vegetação, nomeadamente NDII, GVMI, DER56, NBR e MSI, tiveram um grau de importância relativamente ao %IncMSE

superior a 10%. Todos esses índices de vegetação possuem a presença dos canais infravermelho próximo (NIR: 0,85 - 0,88 μm) e infravermelho de ondas curtas (SWIR1: 1,57 - 1,65 μm , SWIR2: 2,11 - 2,29 μm) em seus respectivos cálculos. Isso indica a importância dos canais infravermelho próximo e infravermelho de ondas curtas para estimativas de carga tanto pelos modelos de *Random Forest* quanto pelas análises de regressão linear múltiplas. Os canais infravermelho próximo e infravermelho de ondas curtas têm sido utilizados para estimar características da vegetação em diversos ambientes (CHUVIECO et al., 2002; PETERSON; ROBERTS; DENNISON, 2008).

No geral, as métricas estatísticas utilizadas para avaliar os modelos foram superiores para os modelos *Random Forest* em relação às equações de regressão linear múltipla e aos modelos k-NN. Assim, os modelos que estimam o combustível superficial campestre do Cerrado pelo algoritmo *Random Forest* com dados recuperados de imagens de satélite forneceram melhores estimativas do combustível superficial. Apenas a variável combustível fino total (vivo e morto) estimada pela análise de regressão linear múltipla resultou em coeficiente de determinação (R^2) um pouco superior, considerando todo o período seco na área de estudo. No entanto, os valores de RMSE e MAE foram superiores aos do algoritmo *Random Forest*.

Alinhado com os resultados deste estudo, D'este et al. (2021) avaliaram o desempenho de modelos de aprendizado de máquina na estimativa da carga de combustível fino em uma região da Itália. Observaram maior poder preditivo para o algoritmo *Random Forest*, com $R^2 = 0,50$, comparado aos modelos de regressão linear múltipla (RLM) e máquinas de vetores de suporte (*Support Vector Machine* – SVM), que apresentaram coeficientes de determinação de 0,40 e 0,39, respectivamente. Em comparação com o presente estudo, apesar das diferentes características do combustível, os valores de R^2 para estimativa da carga de combustível morto fino (< 0,64 cm de diâmetro), pelo *Random Forest*, tiveram melhor desempenho ($R^2 = 0,83$).

A aplicação do algoritmo k-NN para estimar o combustível superficial da fitofisionomia vegetal campestre de Cerrado foi insatisfatória, apresentando métricas estatísticas inferiores às análises de regressão linear múltipla e ao algoritmo *Random Forest*. Isso pode ocorrer porque o algoritmo k-NN tem melhor desempenho e aplicação mais abrangente na estimativa de variáveis florestais (CHIRICI et al., 2016; GAO et al., 2018; MURA et al., 2016; ZHANG et al., 2022) e devido ao pouco

conhecimento de sua avaliação para estimativas de características de combustíveis superficiais.

6 CONCLUSÕES

As análises de regressão linear múltiplas apresentaram melhores métricas estatísticas para as equações ajustadas para o início da estação seca (maio e junho) em comparação às ajustadas para o final da estação seca (agosto e setembro). Tal comportamento decorre das diversas mudanças nas características dos combustíveis de fitofisionomia campestre de Cerrado (campo limpo e campo sujo) durante o início e o final da estação seca. Portanto, a modelagem para obter estimativas de carga, umidade e outras características do combustível superficial deve ser realizada separadamente e considerar a sazonalidade ao longo do ano.

O uso do algoritmo *Random Forest* (RF) contribuiu para melhorias nas métricas de avaliação para estimar a carga de combustível superficial campestre de Cerrado em comparação com as análises de regressão linear múltiplas e quanto ao algoritmo *k-Nearest Neighbors*. Das variáveis preditoras originadas dos produtos das imagens Landsat 8 OLI, a variável fração solo (FS) da análise de mistura espectral exerceu a maior importância para estimativa de carga nas diferentes classes de combustível analisadas. Dessa forma, a aplicação do algoritmo RF e da variável fração solo é recomendada para estimar a carga combustível do Cerrado em fitofisionomias campestres ou de savana. Os índices de vegetação também tiveram considerável importância na aplicação do algoritmo RF, principalmente os índices NDII, GVMI, DER56, NBR e MSI, que apresentaram valores de importância superiores aos demais nas estimativas das variáveis de combustível superficial analisadas.

Porém, o desempenho das estimativas por meio de análises de regressão linear múltiplas e algoritmo *Random Forest* em fitofisionomias mais fechadas e com presença mais significativa de espécies arbóreas, por exemplo, é desconhecida. Novos estudos devem ser realizados para verificar a viabilidade da utilização dos produtos de diferentes imagens de satélite em diferentes ambientes, principalmente nas áreas mais propensas a incêndios no bioma.

REFERÊNCIAS

- AVAND, M.; JANIZADEH, S.; NAGHIBI, S. A.; POURGHASEMI, H. R.; BOZCHALOEI, S. K.; BLASCHKE, T. A comparative assessment of Random Forest and k-Nearest Neighbor classifiers for gully erosion susceptibility mapping. **Water**, [S. l.], v. 11, n. 10, p. 2076, 2019. DOI: 10.3390/W11102076.
- BAO, W.; YU, F.; CHANG, Y.; GUO, M.; ZHOU, F.; ZHONG, C. Estimation of fuel load using remote sensing data in Hulunbuir Grassland. **Natural Hazards Research**, [S. l.], v. 2, n. 4, p. 375–383, 2022. DOI: 10.1016/J.NHRES.2022.11.004.
- BELGIU, M.; DRĂGU, L. Random forest in remote sensing: a review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 114, p. 24–31, 2016. DOI: 10.1016/J.ISPRSJPRS.2016.01.011.
- BREIMAN, L. Random Forests. **Machine Learning**, [S. l.], v. 45, n. 1, p. 5–32, 2001. DOI: 10.1023/A:1010933404324.
- BROWN, J. K.; OBERHEU, R. D.; JOHNSTON, C. M. Handbook for inventorying surface fuels and biomass in the Interior West. **Gen. Tech. Rep. INT-129. Ogden, UT: U.S. Department of Agriculture, Forest Service, Intermountain Forest and Range Experimental Station**. 48 p., [S. l.], v. 129, 1982. DOI: 10.2737/INT-GTR-129.
- CAWSON, J. G.; NYMAN, P.; SCHUNK, C.; SHERIDAN, G. J.; DUFF, T. J.; GIBOS, K.; BOVILL, W. D.; CONEDERA, M.; PEZZATTI, G. B.; MENZEL, A. Estimation of surface dead fine fuel moisture using automated fuel moisture sticks across a range of forests worldwide. **International Journal of Wildland Fire**, [S. l.], v. 29, p. 548–559, 2020. DOI: 10.1071/WF19061.
- CHIRICI, G.; MCROBERTS, R. E.; FATTORINI, L.; MURA, M.; MARCHETTI, M. Comparing echo-based and canopy height model-based metrics for enhancing estimation of forest aboveground biomass in a model-assisted framework. **Remote Sensing of Environment**, [S. l.], v. 174, p. 1–9, 2016. DOI: 10.1016/J.RSE.2015.11.010.
- CHRYSAFIS, I.; MALLINIS, G.; GITAS, I.; TSAKIRI-STRATI, M.. Estimating Mediterranean forest parameters using multi seasonal Landsat 8 OLI imagery and an ensemble learning method. **Remote Sensing of Environment**, [S. l.], v. 199, p. 154–166, 2017. DOI: 10.1016/J.RSE.2017.07.018.
- CHUVIECO, E.; RIAÑO, D.; AGUADO, I.; COCERO, D. Estimation of fuel moisture content from multitemporal analysis of Landsat Thematic Mapper reflectance data: Applications in fire danger assessment. **International Journal of Remote Sensing**, [S. l.], v. 23, n. 11, p. 2145–2162, 2002. DOI: 10.1080/01431160110069818.
- CUI, L.; JIAO, Z.; DONG, Y.; SUN, M.; ZHANG, X.; YIN, S.; DING, A.; CHANG, Y.; GUO, J.; XIE, R. Estimating forest canopy height using MODIS BRDF data emphasizing typical-angle reflectances. **Remote Sensing**, [S. l.], v. 11, n. 19, p. 2239, 2019. DOI: 10.3390/RS11192239.

DE CARVALHO JUNIOR, W.; CALDERANO FILHO, B.; DA SILVA CHAGAS, C.; BARGE BHERING, S.; RENDEIRO PEREIRA, N.; SARAIVA KOENOW PINHEIRO, H.; Regressão linear múltipla e modelo Random Forest para estimar a densidade do solo em áreas montanhosas. **Pesquisa Agropecuária Brasileira**, [S. l.], v. 51, n. 9, p. 1428–1437, 2016. DOI: 10.1590/S0100-204X2016000900041.

DENNISON, P. E.; ROBERTS, D. A.; PETERSON, S. H.; RECHEL, J. Use of Normalized Difference Water Index for monitoring live fuel moisture. **International Journal of Remote Sensing**, [S. l.], v. 26, n. 5, p. 1035–1042, 2006. DOI: 10.1080/0143116042000273998.

D'ESTE, M.; ELIA, M.; GIANNICO, V.; SPANO, G.; LAFORTEZZA, R.; SANESI, G. Machine learning techniques for fine dead fuel load estimation using multi-source remote sensing data. **Remote Sensing**, [S. l.], v. 13, n. 9, p. 1658, 2021. DOI: 10.3390/RS13091658.

DUBE, T.; MUTANGA, O. Evaluating the utility of the medium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in uMgeni catchment, South Africa. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 101, p. 36–46, 2015. DOI: 10.1016/J.ISPRSJPRS.2014.11.001. Acesso em: 7 ago. 2022.

FRANKE, J.; BARRADAS, A. C. S.; BORGES, M. A.; MENEZES COSTA, M.; DIAS, P. A.; HOFFMANN, A. A.; OROZCO FILHO, J. C.; MELCHIORI, A. E.; SIEGERT, F.. Fuel load mapping in the Brazilian Cerrado in support of integrated fire management. **Remote Sensing of Environment**, [S. l.], v. 217, p. 221–232, 2018. DOI: 10.1016/J.RSE.2018.08.018.

FRAZIER, R. J.; COOPS, N. C.; WULDER, M. A.; KENNEDY, R. Characterization of aboveground biomass in an unmanaged boreal forest using Landsat temporal segmentation metrics. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 92, p. 137–146, 2014. DOI: 10.1016/J.ISPRSJPRS.2014.03.003.

FUSHIKI, T. Estimation of prediction error by using K-fold cross-validation. **Statistics and Computing**, [S. l.], v. 21, n. 2, p. 137–146, 2011. DOI: 10.1007/S11222-009-9153-8.

GAO, X.; DONG, S.; LI, S.; XU, Y.; LIU, S.; ZHA, H.; YEOMANS, J.; LI, Y.; SHEN, H. WU, S.; ZHI, Y. Using the random forest model and validated MODIS with the field spectrometer measurement promote the accuracy of estimating aboveground biomass and coverage of alpine grasslands on the Qinghai-Tibetan Plateau. **Ecological Indicators**, [S. l.], v. 112, p. 106114, 2020. DOI: 10.1016/J.ECOLIND.2020.106114.

GAO, Y.; LU, D.; LI, G.; WANG, G.; CHEN, Qi; LIU, L.; LI, D. Comparative analysis of modeling algorithms for forest aboveground biomass estimation in a subtropical region. **Remote Sensing**, [S. l.], v. 10, n. 4, p. 627, 2018. DOI: 10.3390/RS10040627.

GOLDBERGS, G.; LEVICK, S. R.; LAWES, M.; EDWARDS, A. Hierarchical integration of individual tree and area-based approaches for savanna biomass

uncertainty estimation from airborne LiDAR. **Remote Sensing of Environment**, [S. I.], v. 205, p. 141–150, 2018. DOI: 10.1016/J.RSE.2017.11.010.

JI, L.; WYLIE, B. K.; NOSSOV, D. R.; PETERSON, B.; WALDROP, M. P.; MCFARLAND, J. W.; ROVER, J.; HOLLINGSWORTH, T. N. Estimating aboveground biomass in interior Alaska with Landsat data and field measurements. **International Journal of Applied Earth Observation and Geoinformation**, [S. I.], v. 18, n. 1, p. 451–461, 2012. DOI: 10.1016/J.JAG.2012.03.019.

KANMEGNE TAMGA, D.; LATIFI, H.; ULLMANN, T.; BAUMHAUER, R.; BAYALA, J.; THIEL, M. Estimation of aboveground biomass in agroforestry systems over three climatic regions in west Africa using Sentinel-1, Sentinel-2, ALOS, and GEDI data. **Sensors**, [S. I.], v. 23, n. 1, p. 349, 2022. DOI: 10.3390/S23010349.

KEANE, R. E.; HERYNK, J. M.; TONEY, C.; URBANSKI, S. P.; LUTES, D. C.; OTTMAR, R. D. Evaluating the performance and mapping of three fuel classification systems using Forest Inventory and Analysis surface fuel measurements. **Forest Ecology and Management**, [S. I.], v. 305, p. 248–263, 2013. DOI: 10.1016/J.FORECO.2013.06.001.

KUKAVSKAYA, E. A.; SHVETSOV, E. G.; BURYAK, L. V.; TRETYAKOV, P. D.; GROISMAN, P. Y. Increasing fuel loads, fire hazard, and carbon emissions from fires in central Siberia. **Fire**, [S. I.], v. 6, n. 2, p. 63, 2023. DOI: 10.3390/FIRE6020063/S1.

LI, Y.; QUAN, X.; LIAO, Z.; HE, B. Forest Fuel Loads Estimation from Landsat ETM+ and ALOS PALSAR Data. **Remote Sensing**, [S. I.], v. 13, n. 6, p. 1189, 2021. DOI: 10.3390/RS13061189.

LI, Z. W.; XIN, X. P.; TANG, H.; YANG, F.; CHEN, B. R.; ZHANG, B. H. Estimating grassland LAI using the Random Forests approach and Landsat imagery in the meadow steppe of Hulunber, China. **Journal of Integrative Agriculture**, [S. I.], v. 16, n. 2, p. 286–297, 2017. DOI: 10.1016/S2095-3119(15)61303-X.

LI, Z.; ANGERER, J. P.; JAIME, X.; YANG, C.; WU, X. B. Estimating rangeland fine fuel biomass in western Texas using high-resolution aerial imagery and machine learning. **Remote Sensing**, [S. I.], v. 14, n. 17, p. 4360, 2022. DOI: 10.3390/RS14174360.

LIAW, A.; WIENER, M. Classification and regression by randomForest. [S. I.], v. 2, n. 3, 2002.

MIRANDA, H. S.; SATO, M. N.; NETO, W. N.; AIRES, F. S. Fires in the cerrado, the Brazilian savanna. **Tropical Fire Ecology**, [S. I.], p. 427–450, 2009. DOI: 10.1007/978-3-540-77381-8_15.

MURA, M.; MCROBERTS, R. E.; CHIRICI, G.; MARCHETTI, M. Statistical inference for forest structural diversity indices using airborne laser scanning data and the k-Nearest Neighbors technique. **Remote Sensing of Environment**, [S. I.], v. 186, p. 678–686, 2016. DOI: 10.1016/J.RSE.2016.09.010.

OHMANN, J. L.; GREGORY, M. J.; ROBERTS, H. M. Scale considerations for integrating forest inventory plot data and satellite image data for regional forest

mapping. **Remote Sensing of Environment**, [S. l.], v. 151, p. 3–15, 2014. DOI: 10.1016/J.RSE.2013.08.048.

OU, Q.; LEI, X.; SHEN, C. Individual tree diameter growth models of larch–spruce–fir mixed forests based on machine learning algorithms. **Forests**, [S. l.], v. 10, n. 2, p. 187, 2019. DOI: 10.3390/F10020187.

PETERSON, S. H.; ROBERTS, D. A.; DENNISON, P. E. Mapping live fuel moisture with MODIS data: A multiple regression approach. **Remote Sensing of Environment**, [S. l.], v. 112, n. 12, p. 4272–4284, 2008. DOI: 10.1016/J.RSE.2008.07.012.

PFLUGMACHER, D.; COHEN, W. B.; KENNEDY, R. E. Using Landsat-derived disturbance history (1972–2010) to predict current forest structure. **Remote Sensing of Environment**, [S. l.], v. 122, p. 146–165, 2012. DOI: 10.1016/J.RSE.2011.09.025.

PIERCE, A. D.; FARRIS, C. A.; TAYLOR, A. H. Use of random forests for modeling and mapping forest canopy fuels for fire behavior analysis in Lassen Volcanic National Park, California, USA. **Forest Ecology and Management**, [S. l.], v. 279, p. 77–89, 2012. DOI: 10.1016/J.FORECO.2012.05.010.

ROBERTS, D. A.; DENNISON, P. E.; GARDNER, M. E.; HETZEL, Y.; USTIN, S. L.; LEE, C. T. Evaluation of the potential of Hyperion for fire danger assessment by comparison to the airborne visible/infrared imaging spectrometer. **IEEE Transactions on Geoscience and Remote Sensing**, [S. l.], v. 41, n. 6 PART I, p. 1297–1310, 2003. DOI: 10.1109/TGRS.2003.812904.

RODRÍGUEZ, J. D.; PÉREZ, A.; LOZANO, J. A. Sensitivity analysis of k-fold cross validation in prediction error estimation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, [S. l.], v. 32, n. 3, p. 569–575, 2010. DOI: 10.1109/TPAMI.2009.187.

ROTHERMEL, R. C. A mathematical model for predicting fire spread in wildland fuels. **Forest Service - Rocky Mountain Research Station, Usda**, [S. l.], n. Research Paper INT-115, p. 1–48, 1972.

ROUTH, D.; SEEGMILLER, L.; BETTIGOLE, C.; KUHN, C.; OLIVER, C. D.; GLICK, H. B. Improving the reliability of mixture tuned matched filtering remote sensing classification results using supervised learning algorithms and cross-validation. **Remote Sensing**, [S. l.], v. 10, n. 11, p. 1675, 2018. DOI: 10.3390/RS10111675.

SANTOS, M. M.; BATISTA, A. C.; DA SILVA, A. D. P.; NETO, E. G.; BARRADAS, A. C. S.; GIONGO, M. Characterization and dynamics of surface fuel of Cerrado grassland in Jalapão region – Tocantins, Brazil. **Floresta**, [S. l.], v. 51, n. 1, p. 127–136, 2020. DOI: 10.5380/RF.V51I1.67440.

SANTOS, M. M.; BATISTA, A. C.; DE CARVALHO, E. V.; DE CÁSSIA DA SILVA, F.; PEDRO, C. M.; GIONGO, M. Relationships between moisture content and flammability of campestrial Cerrado species in Jalapão. **Revista Brasileira de Ciências Agrárias**, [S. l.], v. 13, n. 4, p. 1–9, 2018. DOI: 10.5039/AGRARIA.V13I4A5587.

SLIJEPCEVIC, A.; ANDERSON, W. R.; MATTHEWS, S.; ANDERSON, D. H. Evaluating models to predict daily fine fuel moisture content in eucalypt forest. **Forest Ecology and Management**, [S. l.], v. 335, p. 261–269, 2015. DOI: 10.1016/J.FORECO.2014.09.040.

SOARES, R. V.; BATISTA, A. C.; TETTO, A. F. **Incêndios florestais: controle, efeitos e uso do fogo**. 2. ed. rev. Curitiba: 2017. 255 p.

SOUSA, D.; SMALL, C. Global cross-calibration of Landsat spectral mixture models. **Remote Sensing of Environment**, [S. l.], v. 192, p. 139–149, 2017. DOI: 10.1016/J.RSE.2017.01.033.

SUN, H.; GUI, D.; YAN, B.; LIU, Y.; LIAO, W.; ZHU, Y.; LU, C.; ZHAO, N. Assessing the potential of random forest method for estimating solar radiation using air pollution index. **Energy Conversion and Management**, [S. l.], v. 119, p. 121–129, 2016. DOI: 10.1016/J.ENCONMAN.2016.04.051.

SZPAKOWSKI, D. M.; JENSEN, J. L. R. A review of the applications of remote sensing in fire ecology. **Remote Sensing**, [S. l.], v. 11, n. 22, p. 2638, 2019. DOI: 10.3390/RS11222638.

THANH NOI, P.; KAPPAS, M. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine classifiers for land cover classification using Sentinel-2 imagery. **Sensors**, [S. l.], v. 18, n. 1, p. 18, 2017. DOI: 10.3390/S18010018.

TUCKER, C. J. Spectral estimation of grass canopy variables. **Remote Sensing of Environment**, [S. l.], v. 6, n. 1, p. 11–26, 1977. DOI: 10.1016/0034-4257(77)90016-5.

VAN WAGTENDONK, J. W.; ROOT, R. R. The use of multi-temporal Landsat Normalized Difference Vegetation Index (NDVI) data for mapping fuel models in Yosemite National Park, USA. **International Journal of Remote Sensing**, [S. l.], v. 24, n. 8, p. 1639–1651, 2010. DOI: 10.1080/01431160210144679.

WANG, L.; ZHOU, X.; ZHU, X.; DONG, Z.; GUO, W. Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. **The Crop Journal**, [S. l.], v. 4, n. 3, p. 212–219, 2016. DOI: 10.1016/J.CJ.2016.01.008.

XU, Q.; MAN, A.; FREDRICKSON, M.; HOU, Z.; PITKÄNEN, J.; WING, B.; RAMIREZ, C.; LI, B.; GREENBERG, J. A. Quantification of uncertainty in aboveground biomass estimates derived from small-footprint airborne LiDAR. **Remote Sensing of Environment**, [S. l.], v. 216, p. 514–528, 2018. DOI: 10.1016/J.RSE.2018.07.022.

ZARCO-TEJADA, P. J.; RUEDA, C. A.; USTIN, S. L. Water content estimation in vegetation with MODIS reflectance data and model inversion methods. **Remote Sensing of Environment**, [S. l.], v. 85, n. 1, p. 109–124, 2003. DOI: 10.1016/S0034-4257(02)00197-9.

ZENG, N.; REN, X.; HE, H.; ZHANG, L.; ZHAO, D.; GE, R.; LI, P.; NIU, Z. Estimating grassland aboveground biomass on the Tibetan Plateau using a random forest

algorithm. **Ecological Indicators**, [S. l.], v. 102, p. 479–487, 2019. DOI: 10.1016/J.ECOLIND.2019.02.023.

ZHANG, G.; GANGULY, S.; NEMANI, R. R.; WHITE, M. A.; MILESI, C.; HASHIMOTO, H.; WANG, W.; SAATCHI, S.; YU, Y.; MYNENI, R. B. Estimation of forest aboveground biomass in California using canopy height and leaf area index estimated from satellite data. **Remote Sensing of Environment**, [S. l.], v. 151, p. 44–56, 2014. DOI: 10.1016/J.RSE.2014.01.025.

ZHANG, W.; ZHAO, L.; LI, Y.; SHI, J.; YAN, M.; JI, Y. Forest above-ground biomass inversion using optical and SAR images based on a multi-step feature optimized inversion model. **Remote Sensing**, [S. l.], v. 14, n. 7, p. 1608, 2022. DOI: 10.3390/RS14071608/S1.