

Artigos

Uso de drone para a estimativa do material combustível em formações campestres no Cerrado

Using drones for estimating fuel material
in Cerrado grasslands

Igor Viana Souza¹ , Francisca de Cássia Silva da Silva¹ ,
Antonio Carlos Batista^{II} , Gil Rodrigues dos Santos¹ ,
Maria Cristina Bueno Coelho¹ , Marcos Giongo¹ 

¹Universidade Federal do Tocantins, Gurupi, TO, Brasil

^{II}Universidade Federal do Paraná, Curitiba, PR, Brasil

RESUMO

Em busca de alternativas para aprimorar o controle e gerenciamento das ações de prevenção aos incêndios, novas técnicas para quantificação do material combustível têm sido estudadas. Para reduzir os custos e tempo gasto em campo, o uso de sensores multiespectrais e câmera RGB (Red, Green e Blue) vêm se destacando como ferramentas úteis e eficazes na estimativa do material combustível. Nesse contexto, objetivou-se neste trabalho avaliar a viabilidade da utilização de um sensor multiespectral e câmera digital RGB aerotransportada por um multirrotor, para estimativa de carga de material combustível em área de Cerrado por meio de regressão linear. O trabalho foi conduzido em área de formação savânica, onde foram avaliadas 40 amostras de carga de material combustível em parcelas de 1 m², coletando-se também imagens, mediante a um aerolevante, para obtenção de variáveis de reflectância, índices de vegetação e variáveis descritivas do modelo tridimensional. A equação ajustada para prever o conteúdo de material combustível (MCT) na área de estudo revelou-se relevante, com significância estatística ($p < 0,001$), um coeficiente de determinação (R^2) de 0,70 e R^2 ajustado de 0,65. Ao analisar a influência das variáveis no modelo, observou-se que, embora a densidade de pontos no modelo (DPM) apresentasse correlações superiores entre as variáveis, o índice de vegetação NDVI exerceu uma influência mais significativa, evidenciada pelo seu maior peso na equação ajustada.

Palavras-chave: Sensoriamento remoto; VANT; Estimativa

ABSTRACT

In the quest to advance fire prevention and control strategies, new techniques for quantifying combustible material are being explored. Among these, the use of multispectral sensors and red, green, and blue (RGB) cameras has emerged as promising solutions to streamline both cost and time expenditures in the field. This study aimed to assess the feasibility of employing an airborne multispectral sensor and an airborne RGB digital camera, mounted on a multirotor drone, to estimate combustible material load in a Cerrado area through linear regression analysis. Conducted within a savanna formation, the study involved evaluating 40 samples of combustible material load in 1 m² plots. Aerial surveys were conducted to capture images, facilitating the derivation of reflectance variables, vegetation indices, and descriptive parameters of the three-dimensional model. The resulting equation, customized to predict total combustible material within the study area, exhibited considerable significance ($p < 0.001$), accompanied by a determination coefficient (R^2) of 0.70 and an adjusted R^2 of 0.65. Upon analyzing the variables' impact on the model, it became evident that while the point density of the model showed higher correlations, the normalized difference vegetation index wielded notable influence, as indicated by its prominent weight within the adjusted equation.

Keywords: Remote sensing; UAV; Prediction

1 INTRODUÇÃO

O bioma Cerrado é considerado uma das savanas mais diversificadas do mundo, por outro lado, é um dos ecossistemas mais ameaçados, principalmente por ações antrópicas que levam à perda e à fragmentação dos ecossistemas (Strassburg *et al.*, 2017).

A ação antrópica no bioma Cerrado resultou em mudanças significativas no regime de uso do fogo, variando de acordo com a época e a frequência em que ocorre. Essa variabilidade é influenciada principalmente pelo comportamento do fogo (Schmidt *et al.*, 2016). Embora o fogo seja um fator natural e crucial, desempenhando um papel fundamental na formação e modelagem do bioma Cerrado ao longo de milhares de anos, o avanço da urbanização transformou o homem no principal agente causador de incêndios florestais, resultando em prejuízos imensuráveis para o bioma (Soares *et al.*, 2017).

Alguns exemplos desses prejuízos imensuráveis incluem a perda de biodiversidade devido à destruição de habitats naturais, alterações adversas no ciclo hidrológico que comprometem a disponibilidade de recursos hídricos, erosão do solo

decorrente da remoção da cobertura vegetal, e a liberação significativa de gases de efeito estufa durante os incêndios, contribuindo para as mudanças climáticas.

Dessa forma, novas técnicas para a compreensão do comportamento do fogo têm sido estudadas com o objetivo de melhorar a forma de controle e gerenciamento nas ações de prevenção dos incêndios florestais (Tavares, 2017).

O estudo realizado por Santos *et al.* (2018) exemplifica investimentos em procedimentos que aprimoram a compreensão do comportamento do fogo. A pesquisa explorou a relação entre o teor de umidade e a inflamabilidade de espécies do Cerrado campestre na região do Jalapão. Analisando seis espécies em quatro níveis de umidade, os pesquisadores conduziram testes abrangendo a Frequência de ignição, Tempo médio para ignição, Duração da combustão e Altura de chamas.

Segundo Soares *et al.* (2017), o comportamento do fogo envolve três elementos principais da combustão: combustível, oxigênio e calor, conhecido como triângulo do fogo, sendo que o combustível é considerado um material orgânico suscetível à combustão (*e.g.* galhos, ramos, troncos caídos, gramíneas, ervas, arbustos, húmus e turfa), sendo passível de controle. Por outro lado, a quantificação do material combustível em área de Cerrado depara-se com a dificuldade na obtenção de dados em razão da heterogeneidade e diversidade do bioma, tornando a quantificação dispendiosa e complexa por métodos convencionais (Ferraz *et al.*, 2014).

Deste modo, métodos indiretos destacam-se pela facilidade em correlacionar parâmetros da vegetação com variáveis fáceis de serem obtidas, como por exemplo, via sensoriamento remoto (Souza *et al.*, 2018). Os sensores multiespectrais fornecem relações de interações entre o alvo e sua resposta espectral, permitindo caracterizar a vegetação conforme a sua característica espectral (Bendig *et al.*, 2014). Deste modo, a alternativa baseada em sensores aerotransportados, oferece imagens com resoluções espaciais e espectrais mais flexíveis em termos de tempo e capacidade de quantificar a vegetação (Berni *et al.*, 2009).

Dentre os avanços tecnológicos em relação ao processamento de imagens digitais (PDI), destacam-se os sensores multiespectrais e câmeras digitais aerotransportadas de alta resolução, devido a sua facilidade e disponibilidade de dados e são instrumentos acessíveis às pesquisas de campo (Banu *et al.*, 2016).

A grande vantagem da aerofotogrametria quando comparada com os métodos convencionais de mensuração é a alta densidade de pontos levantados proporcionado pelo PDI, resultando em processamento de dados com alta precisão, sendo utilizado como alternativa de baixo custo para a caracterização do alvo (Rodrigues; Gallardos, 2018).

A aplicação da aerofotogrametria para a estimativa de parâmetros da vegetação é exemplificada pelos estudos de Bendig *et al.* (2014), Li *et al.* (2016) e Souza *et al.* (2018). Essas pesquisas, que abordam a estimativa de biomassa em cevada de verão, a estimação da altura do dossel e biomassa em plantações de milho, e a quantificação do material combustível em áreas de Cerrado campo sujo, ilustram de maneira destacada a utilidade prática e inovadora dessa tecnologia no âmbito da análise agrícola e ecológica.

Este trabalho presume que a utilização de sensor multiespectral e sensor fotográfico RGB, aerotransportado por um multirrotor, permite obter parâmetros da vegetação em área de campo sujo no Cerrado e ser aplicado em modelos estatísticos para estimação da carga de material combustível.

Assim, o objetivo deste estudo é avaliar a viabilidade da utilização de um sensor multiespectral e de uma câmera digital RGB aerotransportados por um multirrotor para a estimação da carga de material combustível em áreas de campo sujo no bioma Cerrado. Essa avaliação será conduzida por meio da análise de regressão linear.

2 MATERIAIS E MÉTODOS

2.1 Área de estudo

A pesquisa foi realizada no mês de julho de 2017, período de estiagem no Cerrado, na Terra Indígena Xerente. A área em estudo está localizada no município de Tocantínia, região sul do estado do Tocantins, sob coordenadas centrais S9°39'00" de latitude, W48°07'12" de longitude.

No local, encontram-se áreas em processo de recuperação com predominância de vegetação herbácea rasteira em estado de senescência, ambas localizadas em área de campo sujo no Cerrado. Conforme a classificação de Köppen, o clima predominante na região de estudo é C2wA' a', tipificando-a como clima subúmido com moderada deficiência hídrica no inverno, precipitação média de 1.500 mm e temperatura média de 26,6 °C (Alvares *et al.*, 2014).

2.2 Coleta de dados

Para a realização da aerofotogrametria, foi utilizado um sensor multiespectral Survey3W com resolução de 4.000 × 3.000 pixels, que detecta luz infravermelha (NIR) próximo de 850 nm, vermelha (Red) de 660 nm e verde (Green) de 550 nm e uma câmera FC6310 com resolução de 5.472 × 3.648 pixels e distância focal de 8,8 mm, ambos aerotransportados por um multirrotor, sendo integrado um receptor GPS USB externo no sensor para marcar geograficamente cada imagem capturada.

No plano de voo, estabeleceu-se uma altitude de 100 metros com uma sobreposição de 85% tanto longitudinal quanto lateral. Isso resultou em um *ground sample distance* (GSD) de 2,3 cm, representando o valor de cada pixel na imagem em unidades do terreno. Adicionalmente, foram posicionados alvos artificiais de 1 m² (1 × 1 m) em todas as parcelas. Esses alvos, compostos por placas com demarcações facilitadoras, visam tornar sua identificação nas imagens mais eficiente, contribuindo para a precisão e interpretação dos dados obtidos.

A amostragem do material combustível envolveu 40 parcelas de 1 m² (1 × 1 m), distribuídas aleatoriamente como quadrantes delimitadores. Todo o material vegetal dentro de cada parcela foi coletado no mesmo dia, às 10h, imediatamente após o voo do multirrotor. Posteriormente, o material foi pesado, separado em subamostras armazenadas em sacos de papel Kraft e submetido à secagem em estufa a 70 °C até manter a constância da massa. Essa abordagem teve como objetivo estimar a carga de material combustível (MCT) em cada parcela, extrapolando para toneladas por hectare (t.ha⁻¹).

2.3 Análise de dados

Depois de capturar as imagens com o sensor multiespectral Survey3W, foi necessário prepará-las antes de gerar o modelo digital através do *software* MAPIR Camera Control (MCC), onde foi realizada a conversão das fotos de RAW para o formato TIFF, posteriormente realizada a calibração das imagens. Este procedimento é um fator importante que contribui para aumentar a qualidade das imagens, devido à variabilidade espectral (Jorge; Inamasu, 2014).

Após a preparação das imagens foi gerado o modelo tridimensional por meio da execução do algoritmo *structure from motion* (SfM), que a partir de várias fotografias sobrepostas reconstrói a área em três dimensões. O modelo tridimensional foi convertido para modelo digital NGR (Red, Green, Nir). Dessa forma, cada pixel possui um valor de reflectância conhecido em porcentagem. Em seguida, calculou-se o NDVI (Índice de Vegetação Diferença Normalizada) conforme Rouse *et al.* (1974), Equação (1) e NGRDI (Índice de Diferença Normalizada Verde - Vermelho) de acordo com Hunt *et al.* (2005), Equação (2):

$$NDVI = \frac{Nir - Red}{Nir + Red} \quad (1)$$

$$NGRDI = \frac{Green - Red}{Green + Red} \quad (2)$$

Em que: Nir, é a região espectral do infravermelho próximo (850 nm); Red, é a região espectral vermelha (660 nm); Green, é a região espectral verde (550 nm).

O NDVI é o resultado de uma expressão matemático que varia entre -1,0 e 1,0, sendo bastante utilizado em estudo da cobertura vegetal. O índice é dividido em classes, podendo ser adaptativo conforme a característica da vegetação estudada, assim aderiu-se a seguinte divisão apresentado na Tabela 1. Com os valores do NDVI, é possível realizar diagnóstico do índice de área foliar, biomassa, porcentagem de cobertura do solo, atividade fotossintética e produtividade.

Tabela 1 – Classificação dos valores de NDVI

NDVI	Interpretação
-1,0 - 0,0	Ausência de Cobertura Vegetal
0,0 - 0,2	Vigor vegetativo baixo
0,2 - 0,4	Vigor vegetativo moderado
0,4 - 0,6	Vigor vegetativo alto
0,6 - 1,0	Vigor vegetativo muito alto

Fonte: Aquino (2017)

O NGRDI é um índice proposto por Motohka *et al.* (2010) em seu estudo como um complemento e alternativa ao NDVI, em razão da sensibilidade do índice em detectar alterações das cores da vegetação; sendo assim, é importante a aplicabilidade do NGRDI para melhorar avaliação da cobertura vegetal.

As imagens capturadas pela câmera FC6310, foram processadas pelo mesmo algoritmo SfM gerando o modelo tridimensional, exportado em formato LAS, para formação de novas variáveis: Zmín, Zmáx, Zmean, cujos valores correspondem a altitude em centímetros no modelo digital de elevação e DPM, que se refere à quantidade de pontos na nuvem de pontos densa, em uma área de 1 m². Assim, os dados de cada banda espectral (Nir, Green e Red), índices de vegetação (NDVI e NGRDI) e medidas descritivas do modelo tridimensional foram extraídos para cada parcela e tabulados com auxílio de software SIG.

Foi realizada análise descritiva das variáveis MCT, Red, Green, Nir, NDVI, NGRDI, Zmín, Zmáx, Zmean e DPM, sendo posteriormente analisada a correlação de Pearson ($p < 0,05$) entre a variável dependente MCT e as demais variáveis. Para

ampliar a quantidade de estimadores a serem utilizados nas análises, foram feitas transformações das variáveis em $\ln(x)$, $\log(x)$, $1/x$, x^2 e x^3 . Para os ajustes de equações de regressão linear foi utilizado o método de ajuste Stepwise, levando em consideração a variável dependente MCT em $t.ha^{-1}$ e os estimadores supracitados e suas respectivas transformações.

A escolha do modelo ajustado foi analisada por meio da análise gráfica dos resíduos em porcentagem, erro padrão de estimativa em porcentagem (Syx%), valor do coeficiente de determinação (R^2), valor do coeficiente de determinação ajustado (R^2_{aj}) e histograma dos resíduos em porcentagem. Para a identificação das variáveis preditoras mais relevantes no modelo de regressão, os valores dos coeficientes foram padronizados, assim os preditores em diferentes escalas permitem realizar a comparação direta entre os seus coeficientes, além disso foi observado a hipótese de não-colinearidade (Myers, 1990; Bowerman; O'Connell, 1990; Menard, 1995).

3 RESULTADOS E DISCUSSÕES

3.1 Análise descritiva

Os resultados da análise descritiva dos parâmetros utilizados estão apresentados na Tabela 2. Os valores de reflectância média em porcentagem, representados por Red (21,98%), Green (11,47%) e Nir (25,23%), retratam as características físico-químicas da vegetação, onde a absorvância, processo em que ocorre a absorção da radiação eletromagnética da planta, é explícita principalmente nos comprimentos de ondas Red e Nir que são faixas ligadas ao processo de fotossíntese e conseqüentemente ao vigor vegetativo da planta (Geipel *et al.*, 2014).

Em termos de médias, nota-se que os valores dos índices de vegetação NDVI (0,07) e NGRDI (-0,22) classificam a vegetação em baixo vigor vegetativo e ausência de cobertura vegetal, respectivamente, conforme a classificação dos valores de NDVI.

A sazonalidade do bioma Cerrado tem como principal característica dois períodos

definidos, cujo período seco se estende de abril a setembro e chuvoso de outubro a março (SEPLAN, 2012). Essa particularidade do Cerrado, resulta diretamente nos valores descritivos dos dados, especialmente nas variáveis de reflectância e índices de vegetação, as quais são influenciadas pelo vigor da vegetação (Marcussi *et al.*, 2010).

Tabela 2 – Análise descritiva

Parâmetros	Mínimo	Média	Máximo	CV%
Red	13,18	21,98	30,26	22,03
Green	5,97	11,47	16,20	22,13
Nir	14,68	25,23	33,04	20,46
NDVI	-0,03	0,07	0,14	61,08
NGRDI	-0,48	-0,22	0,39	56,70
Zmín (cm)	199,04	255,70	320,91	14,36
Zmáx (cm)	358,35	492,68	607,16	15,39
Zmean (cm)	300,79	360,39	421,46	10,17
DPM (p. m ⁻²)	201,00	406,56	655,00	26,55
MCT (t. ha ⁻¹)	1,79	4,66	7,60	29,97

Fonte: Autores (2022)

Em que: Red, Green e Nir referem-se aos valores de reflectância em porcentagem; NDVI e NGRDI aos índices de vegetação; Zmín, Zmáx e Zmean, altitude em centímetros; DPM, quantidade de pontos por metro quadrado; MCT, carga de material combustível em tonelada por hectare.

3.2 Correlação de *Pearson* e regressão linear

Na Tabela 3, estão apresentados os resultados da correlação de *Pearson* entre a variável dependente MCT e as variáveis independentes: Red, Green, Nir, NDVI, NGRDI, Zmín (cm), Zmáx (cm), Zmean (cm) e DPM (p.m⁻²), e suas respectivas transformações.

O coeficiente de correlação de *Pearson* para variável dependente MCT e as variáveis independentes de reflectância Red, Ln (Red), Log (Red), Red², Red³, Green² e Green³ apresentaram correlações fracas e inversas, sendo significativas a 5% de probabilidade ($r = -0,37$, $r = -0,36$ e $r = 0,36$, $r = -0,37$, $-0,31$ e $-0,33$, respectivamente), exceto a variável $1/\text{Red}$ que expressou uma interação fraca e positiva ($r = 0,35$).

O grau de associação entre a variável MCT e os índices de vegetação NDVI, NDVI², NDVI³, mostraram-se com uma correlação positiva ($r = 0,42$, $r = 0,41$ e $r = 0,36$,

respectivamente), com exceção de 1/NDVI e NGRDI² com um $r = -0,31$ para ambas, sendo consideradas fracas e inversas, e somente a variável NDVI apresentou relevância significativa de 1% pelo teste T.

Tabela 3 – Análise descritiva

Variável	r	Variável	r
Red	-0,37*	1 / NDVI	-0,31*
Ln (Red)	-0,36*	NGRDI ²	-0,31*
Log (Red)	-0,36*	Z Mean	-0,32*
Red ²	-0,37*	Z Mean ²	-0,33*
Red ³	-0,36*	Z Mean ³	-0,35*
1 / Red	0,35*	DPM	0,49**
Green ²	-0,31*	Ln (DPM)	0,49**
Green ³	-0,33*	Log (DPM)	0,49**
NDVI	0,42**	DPM ²	0,48**
NDVI ²	0,41**	DPM ³	0,46**
NDVI ³	0,36*	1/ DPM	-0,47**

Fonte: Autores (2022)

Em que: Red, Green e Nir, referem-se aos valores de reflectância; NDVI e NGRDI aos índices de vegetação; Z Mean e DPM às estatística do modelo tridimensional; Red², Green², NDVI², NGRDI², Z Mean² e DPM² às variáveis elevadas ao quadrado; Red³, Green³, NDVI³, Z Mean³ e DPM³ às variáveis elevadas ao cubo; 1/Red, 1/NDVI e 1/PointCount ao inverso de Red, NDVI e DPM, respectivamente; Log = logaritmo na base 10; Ln = logaritmo natural; r = correlação de Pearson; * e ** = significativo a 5% e 1% pelo teste T, respectivamente.

As variáveis da descritiva do modelo tridimensional, especificamente: DPM, Ln (DPM), Log (DPM), DPM², DPM³ e 1/ DPM; mostraram-se com correlações superiores, no entanto ainda consideradas fracas ($r = 0,49$, $r = 0,49$, $r = 0,49$, $r = 0,48$, $r = 0,46$ e $r = -0,47$, respectivamente) quando comparadas com as variáveis de reflectância e com os índices de vegetação. As variáveis Zmean, Zmean², Zmean³, apresentaram correlações inversas e fracas ($r = -0,32$, $r = -0,33$ e $r = -0,35$, respectivamente). Assim como NDVI, a variável DPM apresentou relevância estatística de 1% de probabilidade.

É possível observar que à medida que se manipulam as bandas espectrais Red e Nir, transformando em NDVI, ocorre o aumento da correlação com a variável MCT.

Tumlisan (2017) ressalta a importância da combinação e transformação das variáveis em novos índices para uma melhor interpretação da cobertura vegetal.

Segundo Ponzoni *et al.* (2015), o processo de fotossíntese de uma vegetação sadia absorve entre 80% e 90% do espectro visível, refletindo entre 40% e 50% do Nir. Dessa forma, ao aplicar a expressão do índice de diferença normalizada ocorre um realce da vegetação onde o brilho é proporcional ao vigor vegetativo da vegetação.

O coeficiente de correlação do material combustível com NGRDI apresentou uma fraca correlação. Trabalhos de Li *et al.* (2016) e Jannoura *et al.* (2015), em área de agricultura de precisão, resultaram em índices com grau de interação moderada, variando entre $r = 0,55$ e $r = 0,74$. Por outro lado, os autores Souza *et al.* (2018) obtiveram um $r = 0,41$, para interação de material combustível e NGRDI em área de campo sujo no Cerrado. Para Tumlisan (2017), os comprimentos de ondas RGB, tendem a refletir menos, conforme a planta apresenta maior disponibilidade de clorofila, e desse modo, o NGRDI, está associado à atividade fotossintética, assim como o NDVI.

A variável ZMean, que corresponde à elevação dos pontos em centímetros, expressou fraca correlação ($r = 0,32$), tornando-se necessário melhorar a classificação dos pontos, como realizada pelos autores Bendig *et al.* (2014), Cunliffe *et al.* (2016), Geipel *et al.* (2014) e Souza *et al.* (2018), que após o processo obtiveram o modelo digital de altura normalizada.

A variável DPM, obteve notoriedade neste trabalho expressando um $r = 0,49$, sendo que a quantidade de pontos das parcelas permitiu uma melhor segmentação da vegetação, tornando-se diretamente proporcional à quantidade de material combustível presente nas parcelas.

Dada a importância das variáveis nas análises de correlação de Pearson, a equação ajustada pelo método de stepwise para estimar a carga de material combustível a partir de dados do sensor multiespectral e câmera RGB, encontra-se na Tabela 13. O ajuste do modelo F (interação) tem um valor significativo de $p < 0,01$ de probabilidade, ou seja, a relação entre as variáveis é relevante e explica a variável resposta MCT e

ao avaliar a hipótese de não – multicolinearidade, nota-se que os valores do Fator de Inflação da Variância (FIV) são menores que 10 e, portanto, os resultados indicam que não existe colinearidade. Myers (1990), Bowerman e O’Connell (1990) sugerem que FIV maior do que 10 pode tornar o modelo de regressão tendencioso e Menard (1995) diz que tolerância inferior a 0,20 é motivo de preocupação.

Tabela 4 – Ajuste da equação de regressão

Y	X	C	C.P	R ²	R ² aj	Syx%	F	M.C	
								T	FIV
	β0	-12,31***					16,06		
	Ln (DPM)	2,69***	0,54				(p <0,01)	0,95	1
MCT	NDVI	18,81***	0,6	0,7	0,65	17,56		0,74	1,3
	Red ³	-6,93e-5**	-0,36					0,84	1,1
	1/NGRDI	-0,19**	-0,32					0,71	1,4

Fonte: Autores (2022)

Em que: C, coeficiente; C.P, coeficiente padronizado; M.C, multicolinearidade; T, tolerância e FIV, Fator de inflação da variância; **, significativo a 1% e ***, significativo a 0,1% de probabilidade


O coeficiente de determinação para a equação foi $R^2 = 0,70$ e $R^2_{aj} = 0,65$, e, ao observar a importância das variáveis, todas foram fortemente significativas pelo teste T. Ainda, analisando a relevância de cada variável para o modelo, observa-se que apesar de Ln (DPM) apresentar uma das melhores correlações apresentados na Tabela 13, o NDVI no ajuste do modelo teve maior peso quando comparado às demais variáveis, podendo ser observado na coluna do Coeficiente Padronizado (C.P).

Yue *et al.* (2017) e Bendig *et al.* (2015), com o propósito de estimar a biomassa da vegetação por meio do NDVI, obtiveram um $R^2 = 0,37$ e $R^2 = 0,48$, respectivamente. Além disso, Yue *et al.* (2017) utilizaram os comprimentos de ondas Green e Red com o mesmo objetivo, alcançando coeficientes de determinação de 0,56 e 0,59, respectivamente.

Nota-se no histograma de frequência de erros, apresentados na Figura 1, que 45% dos erros estão situados no intervalo de 10% |- 20%, sendo indicativo que os erros não têm tendência, respeitando o valor de $Syx\% = 17,56$, para o intervalo de menores erros 1% |- 10%, aproximadamente 8% se situaram nessa região.

Os autores Geipel *et al.* (2014), Bendig *et al.* (2015) e Souza *et al.* (2018) ressaltam a importância da combinação das variáveis, uma vez que a integração de variantes melhora significativamente o desempenho do modelo, tendo ganhos nos ajustes e redução do erro padrão residual.

Figura 1 – Histograma de frequência de erro



Fonte: Autores (2022)

3 CONCLUSÕES

O uso dos sensores remotos em DRONE demonstra grande potencial na avaliação quantitativa do material combustível em área com vegetação de campo sujo em área de Cerrado. Os sensores multiespectral Survey3W e FC6310 demonstram-se como uma alternativa viável para coleta de dados por meio da captura de imagens. Assim, com as hipóteses e objetivos propostos para o presente estudo, conclui-se que:

1- Os índices de vegetação NDVI e NGRDI possuem uma correlação moderada com a carga do material combustível.

2- A variável densidade de ponto no modelo (DPM) foi a variável que apresentou a maior correlação com a carga do material combustível;

3- A equação ajustada para a estimativa da carga do material combustível mostrou-se grande potencial de utilização para na estiva dos combustíveis em área de campo sujo, no Cerrado.

REFERÊNCIAS

- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. Koppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, p.711-728, 2014. <http://dx.doi.org/10.1127/0941-2948/2013/0507>
- BANU, P. T. J.; BORLEA, F. G.; BANU, C. The use of drones in forestry. **Journal of Environmental Science and Engineering**, v. 05, n. 01, p.557-562, 2016. <https://doi.org/10.17265/2162-5263/2016.11.007>
- BENDIG, J.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; EICHFUSS, S.; BARETH, G. Estimating biomass of barley using crop surface models (CSMs) derived from UAV – based RGB imaging. **Remote Sensing**, v. 6, n. 11, p.10395-10412, 2014. <https://doi.org/10.3390/rs61110395>
- BENDIG, J.; Yu, K.; Aasen, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GNYP, L. M.; BARETH, G. Combining UAV-based plant height from crop surface models, visible and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p.79-87, 2015. <http://dx.doi.org/10.1016/j.jag.2015.02.012>
- BERNI, J. A. J.; TEJADA, Z. J. P.; FERES, E. Thermal and Narrowband Multispectral Remote sensing for vegetation monitoring from an unmanned aerial vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 01, n. 01, p.01-17, 2009. <https://doi.org/10.1109/TGRS.2008.2010457>
- BOWERMAN, B. L, O'CONNELL, R. T. **Linear statistical models: an applied approach**. 2. ed. Belmont (CA): Duxbury, 1990.
- CUNLIFFE, A. M.; BRAZIER, R. E.; ANDERSON, K. Ultra-fine grain landscape-scale quantification of dryland vegetation structure with drone-acquired structure-from-motion photogrammetry. **Remote Sensing of Environment**, v. 183, p.129-143, 2016. <https://doi.org/10.1016/j.rse.2016.05.019>
- FERRAZ, A. S.; SOARES, V. P.; SOARES, C. P. B.; RODY, Y. P.; RIBEIRO, C. A. A. S.; BINOTI, D. H. B.; LEITE, H. G.; LEITE, F. P. Estimativa do estoque de biomassa em um fragmento florestal usando imagens orbitais. **Floresta e Ambiente**, v. 21, n. 3, p.286-296, 2014.
- GEIPEL, J.; LINK, J.; CLAUPEIN, W. Combined spectral and spatial modeling of corn yield based on aerial imagens and crop surface models acquired with an unmanned aircraft system. **Remote Sensing**, v. 6, n. 11, p.10335-10355, 2014. <http://doi.org/10.3390/rs61110335>
- HUNT, E. R.; CAVIGELLI, M.; DAUGHTRY, C. S. T.; MCMURTREY, J. E.; WALTHALL, C. L. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, p.359-378, 2005.

JANNOURA, R.; BRINKMANN, K.; UTEAU, D.; BRUNS, C.; JOERGENSEN, R. G. Monitoring of crop biomass using true colour aerial photographs taken from a remote controlled hexacopter. **Biosystems Engineering**, v. 129, p.341-351, 2015. <https://doi.org/10.1016/j.biosystemseng.2014.11.007>

JORGE, L. A. C.; INAMASU, R. Y. **Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão**. Embrapa Instrumentação, 2014. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1003485/uso-de-veiculos-aereos-nao-tripulados-vant-em-agricultura-de-precisao>. Acesso em: 24 out. 2022.

LI, W.; NIU, Z.; CHEN, H.; LI, D.; WU, M.; ZHAO, W. Remote estimation of canopy height and aboveground biomass of maize using high-resolution stereo images from a low-cost unmanned aerial vehicle system. **Ecological Indicators**, v. 67, n. 01, p.637-648, 2016. <http://dx.doi.org/10.1016/j.ecolind.2016.03.036>

MARCUSSI, B. A.; BUENO, P. R. C.; MIQUELONI, P. D.; ARRAES, L. C. Utilização de índices de vegetação para os sistemas de informação geográfica. **Caminhos de geografia**, v. 11, n. 35, p.353-362, 2010.

MENARD, S. **Sage university paper series on quantitative applications in the social sciences**. Applied logistic regression analysis, Sage Publications Thousand Oaks, California, 1995.

MOTOHKA, T.; NASAHARA, K.; HIROYUKI, O.; SATOSHI, T. Applicability of green-red vegetation index for remote sensing of vegetation phenology. **Remote Sensing**, v. 02, n. 01, p.2369-2387, 2010. <https://doi.org/10.3390/rs2102369>

MYERS, R. **Classical and modern regression with applications**. 2. ed. Boston (MA): Duxbury. 1990, p.488.

PONZONI, J. F.; SHIMABUKURU, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2. ed. Atualizada e ampliada, São Paulo, SP: Oficina de Textos, 2015. 45p.

RODRIGUES, R. A; GALLARDO, F. C. L. A. Vantagens da aerofotogrametria por drone na obtenção de dados topográficos em estudos de lixões e aterros sanitários. *In*: VII simpósio internacional de gestão de projetos, inovação e sustentabilidade. **Anais**. São Paulo, 2018. p. 01-15.

ROUSE, W.; HAAS, H. R.; SCHELL, A. J.; DEERING, W. D. **Monitoring vegetation systems in the Great Plains with ERT**. 1. ed. Washington, NASA: third earth resources technology Satellite-1 symposium, 1974, 309 p.

SANTOS, M. M.; BATISTA, C. A.; CARVALHO, E. DE.; SILVA, C. F. DE. Relationships between moisture content and flammability of campestrial Cerrado species in Jalapão. **Revista Brasileira de Ciências Agrárias**, v. 13, n. 04, p.1-9, 2018. <https://doi.org/10.5039/agraria.v13i4a5587>

SCHMIDT, B.; FONSECA, B. C.; FERREIRA, C. M.; SATO, N. M. Experiências internacionais de manejo integrado do fogo em áreas protegidas – recomendações para implementação de manejo integrado de fogo no Cerrado. **Biodiversidade Brasileira**, v. 06, n. 02, p.41-54, 2016.

SEPLAN - Secretaria do Planejamento Superintendência do Planejamento e Gestão Central de Políticas Públicas (SEPLAN). Diretoria de Zoneamento Ecológico-Econômico (DEZ). **Base de dados geográficos do Tocantins**, Palmas, SEPLAN/DEZ, 2012. Disponível em: <https://www.to.gov.br/seplan/base-de-dados-geograficos-do-tocantins-atualizacao-2012/d7n1qsd70x2>. Acessado em: 20 out. 2022.

SOARES, V. R.; BATISTA, C. A.; TETTO, A. F. **Incêndios Florestais: Controle, efeitos e uso do fogo**. 2. ed. Curitiba, Paraná: UFPR, 2017. 47p.

SOUZA, V. I.; SANTOS, M. M.; GIONGO, M.; CARVALHO, V. E. de.; MACHADO, S. E. I. Estimativa do material combustível em área de Cerrado campo sujo a partir de imagens do sensor RGB. **Pesquisa Florestal Brasileira**, v. 3, n. 01, p.01-06, 2018. <https://doi.org/10.4336/2018.pfb.38e201801706>

STRASSBURG, N. B. B.; BROOKS, T.; FELTRAN-BARBIERI, R.; IRIBARREM, A. Moment of truth for the Cerrado hotspot. **Nature ecology & evolution**, v. 01, n. 01, p.1-3, 2017. <https://doi.org/10.1038/s41559-017-0099>

TAVARES, M. E. F. Metodologias usadas na quantificação de material combustível no Cerrado. **Vértices**, v. 19, n. 1, p.175-182, 2017.

TUMLISAN, G. Y. G. **Monitoring growth development and yield estimation of maize using very high-resolution UAV-images in Gronau, Germany**. 2017. 52 p. Dissertação (Mestrado em Geo - Ciência da Informação e Observação da Terra) - University of Twent, Netherlands, 2017.

YUE, J.; YANG, G.; LI, C.; LI, Z.; WANG, Y.; FENG, H.; XU, B. Estimation of winter wheat above-ground biomass using unmanned aerial vehicle-based snapshot hyperspectral sensor and crop height improved models. **Remote Sensing**, v. 9, n. 708, p.01-19, 2017. <https://doi.org/10.3390/rs9070708.36>

Contribuição de Autoria

1 Igor Viana Souza

Engenheiro Florestal, Mestre em Ciências Florestais e Ambientais, Pesquisador <https://orcid.org/0000-0002-0015-6238> • igorvianasousa@gmail.com

Contribuição: Conceitualização; Pesquisa; Validação de dados e experimentos; Redação do manuscrito original

2 Francisca de Cássia Silva da Silva

Engenheira Florestal, Mestra em Ciências Florestais e Ambientais, Pesquisadora <https://orcid.org/0000-0003-4038-7142> • fcassia.silv@gmail.com

Contribuição: Pesquisa; Validação de dados e experimentos; Redação do manuscrito original

3 Antonio Carlos Batista

Engenheiro Florestal, Doutor em Engenharia Florestal, Professor

<https://orcid.org/0000-0001-5929-3838> • batista.ufpr@gmail.com

Contribuição: Conceitualização; Pesquisa; Validação de dados e experimentos; Redação do manuscrito original

4 Gil Rodrigues dos Santos

Engenheiro Agrícola, Doutor em Patologia de Plantas, Professor

<https://orcid.org/0000-0002-3830-9463> • gilrsan@uft.edu.br

Contribuição: Pesquisa; Análise de dados; Escrita – revisão e edição

5 Maria Cristina Bueno Coelho

Engenheira Florestal, Doutor em Ciências Florestais Professor

<https://orcid.org/0000-0003-0409-0624> • mariacristina@uft.edu.br

Contribuição: Pesquisa; Análise de dados; Escrita – revisão e edição

6 Marcos Giongo

Engenheiro Florestal, Doutor em Engenharia Florestal, Professor

<https://orcid.org/0000-0003-1613-6167> • giongo@uft.edu.br

Contribuição: Conceitualização; Curadoria de dados; Recebimento de financiamento; Metodologia; Escrita – revisão e edição

Como citar este artigo

SOUZA, I. V.; SILVA, F. C. S.; BATISTA, A. C.; SANTOS, G. R.; COELHO, M. C. B.; GIONGO, M. Uso de drone para a estimativa do material combustível em formações campestres no Cerrado. **Ciência Florestal**, Santa Maria, v. 34, n. 3, e73469, p. 1-17, 2024. DOI 10.5902/1980509873469. Disponível em: <https://doi.org/10.5902/1980509873469>. Acesso em: dia mês abreviado. ano.