

**UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS E GEODINÂMICA**

DÁCIO JOSÉ CAMBRAIA FILHO

**UTILIZAÇÃO DE ÍNDICES DE VEGETAÇÃO BASEADOS NA PORÇÃO VISÍVEL
DO ESPECTRO ELETROMAGNÉTICO PARA MONITORAMENTO DE
FITOFISIONOMIAS DO CERRADO**

DISSERTAÇÃO DE MESTRADO Nº 157

BRASÍLIA

2019

DÁCIO JOSÉ CAMBRAIA FILHO

**UTILIZAÇÃO DE ÍNDICES DE VEGETAÇÃO BASEADOS NA PORÇÃO VISÍVEL
DO ESPECTRO ELETROMAGNÉTICO PARA MONITORAMENTO DE
FITOFISIONOMIAS DO CERRADO**

Dissertação apresentada ao Programa de Pós-Graduação em Geociências Aplicadas e Geodinâmicas do Instituto de Geociências da Universidade de Brasília, como requisito parcial para a obtenção do grau de Mestre em Geoprocessamento e Análise Ambiental.

Orientador: Prof. Dr. Ricardo Seixas Brites

BRASÍLIA

2019

Cu Cambraia Filho, Dácio José
 Utilização de índices de vegetação baseados na porção visível
do espectro eletromagnético para monitoramento de
fitofisionomias do Cerrado / Dácio José Cambraia Filho;
orientador Ricardo Seixas Brites. -- Brasília, 2019.
 147 p.

 Dissertação (Mestrado - Mestrado em Geociências
Aplicadas) -- Universidade de Brasília, 2019.

 1. Índices de vegetação. 2. Porção visível (VIS). 3.
Cerrado. 4. Aeronave remotamente pilotada (RPA). 5.
Sentinel-2. I. Seixas Brites, Ricardo, orient. II. Título.

CAMBRAIA-FILHO, Dácio José. **Utilização de índices de vegetação baseados na porção visível do espectro eletromagnético para monitoramento de fitofisionomias do Cerrado.** Dissertação (Mestrado) apresentada ao Instituto de Geociências da Universidade de Brasília para obtenção do título de Mestre em Geoprocessamento e Análise Ambiental.

Aprovado em: 30/04/2019

Banca Examinadora



Prof. Dr. Ricardo Seixas Brites

Universidade de Brasília (UnB) - Presidente



Prof. Dr. Edilson de Souza Bias

Universidade de Brasília (UnB) - Examinador interno



Dr. Denilson Pereira Passo

Serviço Florestal Brasileiro - Examinador externo

AGRADECIMENTOS

Primeiramente agradeço a Deus pelo dom da vida e pela capacidade de buscar a realização dos meus sonhos com muita luta, perseverança e dedicação.

Agradeço também aos meus pais Dácio e Célida, juntamente à minha irmã Débora, por terem sonhado junto comigo e me incentivado e apoiado sempre na busca incansável dos meus sonhos. Vocês são meus maiores exemplos e sem vocês eu tenho certeza de que não teria conseguido nada. Lembrem-se que amo muito vocês!

Agradeço à minha namorada Débora pelo carinho, paciência e compreensão em meus momentos de ausência. Seu companheirismo e cumplicidade me fizeram mais forte para seguir em frente, na busca dos meus objetivos. Saiba que você e o Paulo César tiveram uma participação importantíssima nessa conquista, me proporcionando inúmeros momentos felizes, regados a muitos sorrisos em minha segunda casa. Sou muito grato a vocês!

Agradeço também à Universidade de Brasília, juntamente aos professores, servidores públicos e colegas do Instituto de Geociências por terem me recebido de braços abertos e contribuído com minha formação. Vocês me trouxeram momentos únicos com muito companheirismo acompanhados de um vasto conhecimento, sempre que possível. Em especial, agradeço ao meu orientador Ricardo Seixas Brites pela paciência, dedicação e empenho em todo esse período de parceria. O senhor teve um papel de extrema importância durante todo esse período e lhe agradeço muito por todos os ensinamentos a mim transferidos.

Agradeço também a CAPES pela bolsa de mestrado concedida a mim durante o desenvolvimento do programa.

Agradeço também a todos familiares, amigos e conhecidos que de alguma forma contribuíram e estiveram presentes durante todo esse período. Em especial à Ana Carolina (Tina), Marcelo Piau, Vinícius Antônio (Leitão), Lucas Fiuza (Berla), Victor Lucas (DD), Thiago Valadares, Rafael Matos e Gustavo Valadares que me acompanharam nos trabalhos de campo e fizeram daqueles momentos mais agradáveis e felizes de se viver.

A todos vocês, o meu mais profundo e sincero muito obrigado!

RESUMO

CAMBRAIA-FILHO, Dácio José. **Utilização de índices de vegetação baseados na porção visível do espectro eletromagnético para monitoramento de fitofisionomias do Cerrado.** 2019. 147 p. Dissertação (Mestrado) - Instituto de Geociências, Universidade de Brasília, Brasília, 2019.

Considerado como o segundo maior bioma da América do Sul, a savana úmida neotropical brasileira ou Cerrado brasileiro, é considerada um bioma de extrema complexidade, dotado de uma das maiores diversidades biológicas do mundo. Porém, apesar do reconhecimento de sua grande importância ambiental, o Cerrado vem sofrendo com a crescente exploração de seus recursos naturais ao longo do tempo. Nessa perspectiva, inúmeros estudos utilizando dados do sensoriamento remoto vêm sendo propostos com a finalidade de avaliar o grau de suas explorações e determinar as características espectrais das vegetações desse bioma. Dentre as técnicas mais utilizadas para essas investigações, os índices de vegetação servem como fonte de conhecimento básico sobre as coberturas vegetais. Dessa forma, o presente trabalho teve como objetivo avaliar a aplicabilidade dos índices de vegetação de folha verde (GLI), índice de vegetação da diferença normalizada do verde e vermelho (NGRDI) e índice de vegetação com resistência atmosférica ao visível (VARI) em diferentes fitofisionomias do bioma Cerrado a partir de imagens capturadas com uma Aeronave remotamente pilotada (RPA) equipada com câmera RGB convencional. Para o desenvolvimento deste estudo foram utilizadas 73 imagens orbitais e 72 imagens aerolevadas, onde cada um destes conjuntos de dados recebeu o processamento correspondente às suas características individuais. Sobre os dados orbitais, foram aplicados os procedimentos de correção atmosférica e calculados os índices de vegetação, enquanto que para os dados aerotransportados foram desenvolvidos os procedimentos metodológicos para a obtenção dos ortomosaicos e posterior cálculos dos mesmos índices. Após a execução de todos os procedimentos, foi possível notar ao analisar os resultados que mesmo em dados com características distintas, existe um padrão de comportamento semelhante para os índices de vegetação e para as fitofisionomias em ambos os casos. Entretanto, algumas singularidades são observadas para cada um dos conjuntos utilizados, seja por seus comportamentos pontuais ou pelas suas respostas espectro-temporais nas diferentes fitofisionomias. Assim, foi possível concluir que os índices de vegetação que utilizam apenas a faixa do visível apresentam-se uma métrica consistente para análise de dados da vegetação quando utilizadas com imagens advindas de sensores orbitais ou aerotransportados.

Palavras-chave: Índices de vegetação; Porção visível (VIS); Cerrado brasileiro; Aeronave remotamente pilotada (RPA), Sentinel-2.

ABSTRACT

CAMBRAIA-FILHO, Dácio José. **Use of vegetation indices based on the visible portion of the electromagnetic spectrum for the monitoring of Cerrado phytophysionomies.** 2019. 147 p. Dissertation (Masters degree) - Institute of Geosciences, University of Brasília, Brasília, 2019.

Considered as the second largest biome in South America, the Brazilian Neotropical wet savannah or Brazilian Cerrado is considered a biome of extreme complexity, endowed with one of the greatest biological diversities in the world. However, despite the recognition of its great environmental importance, the Cerrado has been suffering from the increasing exploitation of its natural resources over time. In this perspective, numerous studies using remote sensing data have been proposed with the purpose of evaluating the degree of their explorations and determining the spectral characteristics of the vegetation of this biome. Among the techniques most used for these investigations, vegetation indices serve as a source of basic knowledge about vegetation cover. The objective of this study was to evaluate the applicability of green leaf vegetation index (GLI), vegetation index of the normalized difference of green and red (NGRDI) and vegetation index with visible atmospheric resistance (VARI) in different Phytophysionomies of the biome Cerrado from images captured with a Remotely Piloted Aircraft (RPA) equipped with a conventional RGB camera. For the development of this study, 73 orbital images and 72 aerial images were used, where each one of these datasets received the processing corresponding to their individual characteristics. On the orbital data, the atmospheric correction procedures were applied and the vegetation indexes were calculated, while for the airborne data the methodological procedures were developed to obtain the orthomosaic and subsequent calculations of the same indexes. After performing all the procedures, it was possible to notice when analyzing the results that even in data with distinct characteristics, there is a similar pattern of behavior for vegetation indices and for phytophysionomies in both cases. However, some singularities are observed for each of the sets used, either by their punctual behaviors or by their spectral-temporal responses in the different phytophysionomies. Thus, it was possible to conclude that vegetation indexes that use only the visible range are a consistent metric for the analysis of vegetation data when used with images from orbital or airborne sensors.

Keywords: Indices of vegetation; Visible portion (VIS); Brazilian Cerrado; Remotely piloted aircraft (RPA); Sentinel-2.

LISTA DE ILUSTRAÇÕES

Figura 1 - TIROS-1	23
Figura 2 - ERTS-1	23
Figura 3 - Direção de propagação da REM (X, Y, Z) na forma de onda em função das oscilações do campo magnético (M) e elétrico (E) e comprimento de onda (λ)	24
Figura 4 - Absorção da REM com deslocamento de elétrons para orbitais com maior energia	25
Figura 5 - Espectro eletromagnético.....	25
Figura 6 - Comportamento espectral para a água límpida e turva, solo seco e molhado e vegetação ...	26
Figura 7 - Classificação dos sistemas sensores.....	27
Figura 8 - Quadricóptero Phantom 4	29
Figura 9 - Imagem ilustrativa dos satélites S2A e S2B.....	31
Figura 10 - Estrutura interna de uma folha com possíveis comportamentos da REM incidente.....	33
Figura 11 - Localização da área de estudo e das parcelas amostrais.....	39
Figura 12 - (A1, A2) Agricultura; (B1, B2) campo; (C1, C2) floresta nativa; (D1, D2) floresta plantada; (E1, E2) pastagem nativa; (F1, F2) pastagem plantada	39
Figura 13 - Distribuição pluviométrica média local conforme séries históricas de estações convencionais.....	41
Figura 14 - Fluxograma metodológico	43
Figura 15 - Imagens Sentinel-2 referentes as bandas espectrais com 10 metros de resolução espacial: (A) azul, (B) verde, (C) vermelho e (D) NIR	44
Figura 16 - Ortomosaico com pixels normalizados	46
Figura 17 - Reamostragem dos dados aerotransportados de 4,53 cm/pix (A) para 10 m/pix (B).....	48
Figura 18 - Interferências atmosféricas identificadas nas imagens orbitais: (A) nuvens; (B) nuvens parciais; (C) sombras e (D) arco-íris	50
Figura 19 - Distribuição de valores médios para os índices nas diferentes parcelas amostrais	53
Figura 20 - Série temporal referente a parcela de agricultura	55
Figura 21 - Série temporal referente a parcela de campo.....	55
Figura 22 - Série temporal referente a parcela de floresta nativa.....	56
Figura 23 - Série temporal referente a parcela de floresta plantada	57
Figura 24 - Série temporal referente a parcela de pastagem nativa.....	57
Figura 25 - Série temporal referente a parcela de pastagem plantada	58
Figura 26 - Histogramas resultantes do teste de Shapiro-Wilk para dados orbitais (A) e dados aerotransportados (B).....	59
Figura 27 - Correlações entre os índices do visível orbital (dependente) com o NDVI (independente)	59
Figura 28 - Correlações entre os índices do visível aerotransportados (dependente) com o NDVI (independente).....	60

Figura 29 - Histograma resultante do teste de Shapiro-Wilk para os dados orbitais/aerotransportados	61
Figura 30 - Avaliação de erros residuais para dados orbitais (A), aerotransportados (B) e orbitais/aerotransportados (C)	62
Figura 31 - Análise de variância dos índices de vegetação orbitais/aerotransportados ajustado ao modelo GLM com o NDVI	63
Figura 32 - Análise de significância de contrastes dos índices de vegetação orbitais/aerotransportados com dados agrupados por índices e parcelas com o NDVI	63
Figura 33 - Análise de variância dos índices de vegetação ajustados ao modelo GLM para os dados orbitais	64
Figura 34 - Análise de significância de contrastes dos índices de vegetação dos dados orbitais agrupados por índices e parcelas amostrais	65
Figura 35 - Análise de variância dos índices de vegetação ajustados ao modelo GLM para os dados aerotransportados	66
Figura 36 - Análise de significância de contrastes referente aos dados aerotransportados agrupados por índices e parcelas amostrais	66
Figura 37 - Agricultura 28/02/2018 (dia 28)	78
Figura 38 - Agricultura 31/03/2018 (dia 59)	78
Figura 39 - Agricultura 30/04/2018 (dia 89)	78
Figura 40 - Agricultura 31/05/2018 (dia 120)	78
Figura 41 - Agricultura 30/06/2018 (dia 150)	79
Figura 42 - Agricultura 31/07/2018 (dia 181)	79
Figura 43 - Agricultura 31/08/2018 (dia 212)	79
Figura 44 - Agricultura 30/09/2018 (dia 242)	79
Figura 45 - Agricultura 31/10/2018 (dia 273)	80
Figura 46 - Agricultura 30/11/2018 (dia 303)	80
Figura 47 - Agricultura 31/12/2018 (dia 334)	80
Figura 48 - Agricultura 31/01/2019 (dia 365)	80
Figura 49 - Campo 28/02/2018 (dia 28)	81
Figura 50 - Campo 31/03/2018 (dia 59)	81
Figura 51 - Campo 30/04/2018 (dia 89)	81
Figura 52 - Campo 31/05/2018 (dia 120)	81
Figura 53 - Campo 30/06/2018 (dia 150)	82
Figura 54 - Campo 31/07/2018 (dia 181)	82
Figura 55 - Campo 31/08/2018 (dia 212)	82
Figura 56 - Campo 30/09/2018 (dia 242)	82
Figura 57 - Campo 31/10/2018 (dia 273)	83
Figura 58 - Campo 30/11/2018 (dia 303)	83

Figura 59 - Campo 31/12/2018 (dia 334)	83
Figura 60 - Campo 31/01/2019 (dia 365)	83
Figura 61 - Floresta nativa e pastagem plantada 28/02/2018 (dia 28)	84
Figura 62 - Floresta nativa e pastagem plantada 31/03/2018 (dia 59)	84
Figura 63 - Floresta nativa e pastagem plantada 30/04/2018 (dia 89)	84
Figura 64 - Floresta nativa e pastagem plantada 31/05/2018 (dia 120)	84
Figura 65 - Floresta nativa e pastagem plantada 30/06/2018 (dia 150)	85
Figura 66 - Floresta nativa e pastagem plantada 31/07/2018 (dia 181)	85
Figura 67 - Floresta nativa e pastagem plantada 31/08/2018 (dia 212)	85
Figura 68 - Floresta nativa e pastagem plantada 30/09/2018 (dia 242)	85
Figura 69 - Floresta nativa e pastagem plantada 31/10/2018 (dia 273)	86
Figura 70 - Floresta nativa e pastagem plantada 30/11/2018 (dia 303)	86
Figura 71 - Floresta nativa e pastagem plantada 31/12/2018 (dia 334)	86
Figura 72 - Floresta nativa e pastagem plantada 31/01/2019 (dia 365)	86
Figura 73 - Floresta plantada 28/02/2018 (dia 28).....	87
Figura 74 - Floresta plantada 31/03/2018 (dia 59).....	87
Figura 75 - Floresta plantada 30/04/2018 (dia 89).....	87
Figura 76 - Floresta plantada 31/05/2018 (dia 120).....	87
Figura 77 - Floresta plantada 30/06/2018 (dia 150).....	88
Figura 78 - Floresta plantada 31/07/2018 (dia 181).....	88
Figura 79 - Floresta plantada 31/08/2018 (dia 212).....	88
Figura 80 - Floresta plantada 30/09/2018 (dia 242).....	88
Figura 81 - Floresta plantada 31/10/2018 (dia 273).....	89
Figura 82 - Floresta plantada 30/11/2018 (dia 303).....	89
Figura 83 - Floresta plantada 31/12/2018 (dia 334).....	89
Figura 84 - Floresta plantada 31/01/2019 (dia 365).....	89
Figura 85 - Pastagem nativa 28/02/2018 (dia 28).....	90
Figura 86 - Pastagem nativa 31/03/2018 (dia 59).....	90
Figura 87 - Pastagem nativa 30/04/2018 (dia 89).....	90
Figura 88 - Pastagem nativa 31/05/2018 (dia 120).....	90
Figura 89 - Pastagem nativa 30/06/2018 (dia 150).....	91
Figura 90 - Pastagem nativa 31/07/2018 (dia 181).....	91
Figura 91 - Pastagem nativa 31/08/2018 (dia 212).....	91
Figura 92 - Pastagem nativa 30/09/2018 (dia 242).....	91
Figura 93 - Pastagem nativa 31/10/2018 (dia 273).....	92
Figura 94 - Pastagem nativa 30/11/2018 (dia 303).....	92
Figura 95 - Pastagem nativa 31/12/2018 (dia 334).....	92

Figura 96 - Pastagem nativa 31/01/2019 (dia 365).....	92
Figura 97 - 01/03/2018 (dia 29).....	134
Figura 98 - 06/03/2018 (dia 34).....	134
Figura 99 - 16/03/2018 (dia 44).....	134
Figura 100 - 21/03/2018 (dia 49).....	134
Figura 101 - 26/03/2018 (dia 54).....	134
Figura 102 - 05/04/2018 (dia 64).....	134
Figura 103 - 10/04/2018 (dia 69).....	134
Figura 104 - 25/04/2018 (dia 84).....	134
Figura 105 - 30/04/2018 (dia 89).....	135
Figura 106 - 05/05/2018 (dia 94).....	135
Figura 107 - 15/05/2018 (dia 104).....	135
Figura 108 - 09/06/2018 (dia 129).....	135
Figura 109 - 14/06/2018 (dia 134).....	135
Figura 110 - 29/06/2018 (dia 149).....	135
Figura 111 - 04/07/2018 (dia 154).....	135
Figura 112 - 09/07/2018 (dia 159).....	135
Figura 113 - 19/07/2018 (dia 169).....	136
Figura 114 - 24/07/2018 (dia 174).....	136
Figura 115 - 29/07/2018 (dia 179).....	136
Figura 116 - 03/08/2018 (dia 184).....	136
Figura 117 - 08/08/2018 (dia 189).....	136
Figura 118 - 13/08/2018 (dia 194).....	136
Figura 119 - 18/08/2018 (dia 199).....	136
Figura 120 - 23/08/2018 (dia 204).....	136
Figura 121 - 02/09/2018 (dia 214).....	137
Figura 122 - 07/09/2018 (dia 219).....	137
Figura 123 - 12/09/2018 (dia 224).....	137
Figura 124 - 22/09/2018 (dia 234).....	137
Figura 125 - 02/10/2018 (dia 244).....	137
Figura 126 - 16/12/2018 (dia 319).....	137
Figura 127 - 21/12/2018 (dia 324).....	137
Figura 128 - 10/01/2019 (dia 344).....	137
Figura 129 - 20/01/2019 (dia 354).....	138
Figura 130 - 25/01/2019 (dia 359).....	138
Figura 131 - 30/01/2019 (dia 364).....	138
Figura 132 - Plano de voo para parcela amostral de agricultura	139

Figura 133 - Plano de voo para parcela amostral de campo.....	139
Figura 134 - Plano de voo para parcela amostral de floresta nativa e pastagem plantada	140
Figura 135 - Plano de voo para parcela amostral de floresta plantada	140
Figura 136 - Plano de voo para parcela amostral de pastagem nativa.....	141
Figura 137 - Série histórica pluviométrica da estação do Pântano (código 01846006).....	147
Figura 138 - Série histórica pluviométrica da estação da Rocinha (código 01846019)	147

LISTA DE TABELAS

Tabela 1 - Características dos sensores MSI embarcados nos satélites S2A e S2B	31
Tabela 2 - Metodologia de processamento empregada no Agisoft Metashape Professional 1.5	45
Tabela 3 - Descrição de índices de vegetação utilizados	47
Tabela 4 - Resumo descritivo dos valores médios dos índices de vegetação	52
Tabela 5 - Relação de imagens Sentinel-2 utilizadas.....	130
Tabela 6 - Pluviometria média na estação do Pântano (código 01846006).....	143
Tabela 7 - Pluviometria média na estação da Rocinha (código 01846019)	145

LISTA DE ABREVIATURAS E SIGLAS

A	Agricultura
ANAC	Agência Nacional de Aviação Civil
BOA	Base da atmosfera
C	Campo
DN	Números digitais
ERTS-1	<i>Earth Resources Technology Satellite</i>
ESA	Agência Espacial Europeia
EUA	Estados Unidos da América
FN	Floresta nativa
FOV	Campo de visada
FP	Floresta plantada
GLI	Índice de vegetação de folha verde
GLM	Modelo linear generalizado
GMES	Comissão Europeia de Monitoramento Global do Ambiente e Segurança
GSD	Distância de amostragem de solo
IAF	Índice de área foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
L1C	Level-1C
L2A	Level-2A
MSI	Instrumentos multiespectrais
NDVI	Índice de vegetação da diferença normalizada
NGRDI	Índice de vegetação da diferença normalizada do verde e vermelho
NIR	Infravermelho-próximo
PN	Pastagem nativa
PP	Pastagem plantada
REM	Radiação eletromagnética
RPA	Aeronave remotamente pilotada
S2A	Sentinel-2A
S2B	Sentinel-2B
SR	Índice de razão simples
SWIR	Infravermelho-de-ondas-curtas
TIROS-1	<i>Television Infrared Operational Satellite</i>
TOA	Topo da atmosfera
URSS	União das Repúblicas Socialistas Soviéticas
USGS	Serviço Geológico dos Estados Unidos

VANT	Veículo aéreo não tripulado
VARI	Índice de vegetação com resistência atmosférica ao visível
VIS	Visível
VNIR	Visível e infravermelho-próximo

SUMÁRIO

1	INTRODUÇÃO	18
2	OBJETIVO	20
2.1	GERAL	20
2.2	ESPECÍFICOS	20
3	JUSTIFICATIVA	21
4	REFERENCIAL TEÓRICO	22
4.1	SENSORIAMENTO REMOTO.....	22
4.2	FUNDAMENTOS DO SENSORIAMENTO REMOTO	24
4.2.1	RADIAÇÃO ELETROMAGNÉTICA (REM)	24
4.2.2	COMPORTAMENTO ESPECTRAL DOS MATERIAIS.....	25
4.2.3	SISTEMAS SENSORES	27
4.3	SENSORIAMENTO REMOTO DA VEGETAÇÃO	32
4.3.1	ÍNDICES DE VEGETAÇÃO	34
5	MATERIAIS E MÉTODOS	38
5.1	ÁREA DE ESTUDO	38
5.2	MATERIAIS	42
5.3	MÉTODOS	42
5.3.1	DADOS ORBITAIS (1).....	43
5.3.2	DADOS AEROTRANSPORTADOS (2)	44
5.3.3	ÍNDICES DE VEGETAÇÃO (3).....	47
5.3.4	ANÁLISES ESTATÍSTICAS (4)	48
6	RESULTADOS	50
6.1	DADOS UTILIZADOS.....	50
6.2	ESTATÍSTICA DESCRITIVA	51
6.3	SÉRIES TEMPORAIS	54
6.4	ANÁLISES COMPARATIVAS	58
6.5	ANÁLISES DE VARIÂNCIA	61
7	CONCLUSÕES	67
	REFERÊNCIAS	69
	APÊNDICE A - IMAGENS AEROTRANSPORTADAS	78
	APÊNDICE B - ANÁLISE ESTATÍSTICA	93
	APÊNDICE B.1 - SCRIPT	93
	APÊNDICE B.2 - ANÁLISES DOS DADOS ORBITAIS E AEROTRANSPORTADOS COM NDVI	100
	APÊNDICE B.3 - ANÁLISES DOS DADOS ORBITAIS E AEROTRANSPORTADOS	108

APÊNDICE B.4 - ANÁLISES DOS DADOS ORBITAIS	116
APÊNDICE B.5 - ANÁLISES PARA DADOS AEROTRANSPORTADOS	123
ANEXO A - IMAGENS ORBITAIS	130
ANEXO B - PLANOS DE VOO	139
ANEXO C - CERTIDÃO DE CADASTRO DE AERONAVE NÃO TRIPULADA	142
ANEXO D - SÉRIES HISTÓRICAS PLUVIOMÉTRICAS	143

1 INTRODUÇÃO

Reconhecido como o segundo maior bioma da América do Sul, o Cerrado brasileiro, ou savana úmida neotropical brasileira, é um dos biomas inseridos nos limites territoriais do Brasil, composto por um grande mosaico de vegetações, solos, clima e topografia, com características totalmente heterogêneas. Com uma área territorial de 2.036.448 km², o que correspondente à 22% do território nacional brasileiro, é considerado um dos biomas com a maior complexidade ecossistêmica de todo o mundo, principalmente por conta de suas altas taxas de endemismo, elevados níveis de biodiversidade e acentuadas sazonalidades pluviométricas. Do ponto de vista da diversidade biológica, é apontado como sendo a savana mais rica existente, além de ser designado como um dos *hotspots* mundiais da biodiversidade (MYERS et al., 2000; SANO et al., 2009; FERREIRA et al., 2011; MMA, 2019).

Apesar do reconhecimento de sua grande importância ecossistêmica, o Cerrado brasileiro vem sofrendo com a crescente exploração de seus recursos naturais e com as rápidas conversões de suas extensões em espaços ocupados por atividades agrossilvopastoris (GOEDERT, 1989; BUENO et al., 2019). Autores como Sano et al. (2009) indicam que a cobertura vegetal nativa do Cerrado esteja estimada em menos de 61%, enquanto Carvalho et al. (2009) afirma que este bioma vem sofrendo exaustivamente com as altas taxas de fragmentação florestal e com os elevados níveis de degradação ambiental.

A fim de averiguar e analisar essa condição de crescente degradação, inúmeros estudos vêm sendo propostos para avaliar a situação ambiental do Cerrado, de forma que as suas diferentes fitofisionomias sejam avaliadas principalmente quanto às condições de suas coberturas vegetais (CARDOZO et al., 2011; GIBBS; SALMON, 2015). Nessa perspectiva, estudos que avaliam e analisam as propriedades da vegetação com dados advindos do sensoriamento remoto vêm ganhando cada vez mais destaque no meio científico e acadêmico, por desempenhar um papel fundamental no conhecimento do bioma e por auxiliar no mapeamento e monitoramento sustentável de grandes e pequenas extensões (FANG et al., 2016; EMERY; CAMPS, 2017).

Nesse tipo de estudo, onde são empregados dados e técnicas advindas do sensoriamento remoto para reconhecimento das características das vegetações, uma série de avaliações que evidenciam os comportamentos que as radiações eletromagnéticas (REM) assumem ao interagir com a cobertura vegetal são usadas para se extrair informações sobre suas características. E uma das métricas mais utilizadas para demonstrar essas variações são os denominados índices espectrais de vegetação, que servem como um indicador efetivo das

condições fisiológicas, biofísicas e bioquímicas das vegetações em diferentes fitofisionomias (ABREU; COUTINHO, 2014; WHITESIDE; BARTOLO, 2015).

Porém, apesar dos grandes avanços ocorridos ao sensoriamento remoto aeroespacial nas últimas décadas, os dados advindos dos sensores orbitais têm se mostrado cada vez mais limitados ao serem empregados em estudos sobre a vegetação principalmente por conta de suas características espaciais e temporais. Como alternativa para a coleta de informações e utilização nesse tipo de estudo, as aeronaves remotamente tripuladas (RPA) dotadas com sensores imageadores vêm apresentando grande potencial de se obter dados com alta resolução espacial, baixo custo operacional e temporalidade quase em tempo real (BERNI et al., 2009a; HARWIN; LUCIEER, 2012).

Apesar de apresentarem inúmeras vantagens quando comparadas aos satélites convencionais, as RPAs na maioria das vezes contam apenas com sensores digitais que abrangem apenas as bandas espectrais do visível (ZHENG et al., 2018). Lebourgeois et al. (2008) afirma que os dados advindos desse tipo de equipamento podem até fornecer imagens com qualidades satisfatórias, mas geralmente apresentam baixas resoluções radiométricas e devem ser cuidadosamente utilizados em estudos técnico-científicos. No entanto, algumas aplicações os índices de vegetação com dados advindos de RPAs embarcados com sensores RGB convencionais têm apresentado resultados satisfatórios, como mostram Hunt-Jr et al. (2005), Zhu et al. (2009) e Córcoles et al. (2013). Porém, os índices de vegetação que utilizam informações dos comprimentos de onda do infravermelho-próximo (NIR) e/ou infravermelho-de-ondas-curtas (SWIR) ainda se mostram mais robustos e eficientes ao serem empregados em análises sobre vegetação, sendo mais utilizados em estudos desenvolvidos nessa temática em todo o mundo (HUETE, 1988; JORDAN, 1969; TUCKER, 1979).

Sendo assim, o presente estudo tem como finalidade testar a aplicabilidade dos índices de vegetação baseados apenas na porção visível do espectro eletromagnético com dados advindos de um RPA convencional, avaliando suas potencialidades, similaridades e diferenças quando comparados aos índices que empregam informações espectrais do NIR em diferentes fitofisionomias do Cerrado. Essas aplicações foram aqui avaliadas principalmente pelo fato de atualmente os RPAs apresentarem baixo custo de aquisição e grande facilidade de acesso, abrindo assim, novas perspectivas para o monitoramento das vegetações por parte de cientistas, produtores rurais e outros segmentos produtivos que apresentem necessidade de informações específicas sobre as vegetações.

2 OBJETIVO

2.1 GERAL

O presente estudo tem como objetivo avaliar a aplicação dos índices de vegetação baseados na porção visível do espectro eletromagnético, utilizando imagens adquiridas por uma RPA (quadricóptero) convencional equipado com câmera RGB em diferentes fitofisionomias do bioma Cerrado.

2.2 ESPECÍFICOS

- Identificar as semelhanças e diferenças entre os índices de vegetação que utilizam informações espectrais do visível e do infravermelho-próximo (VNIR) em dados advindos de sensores orbitais e aerotransportados;
- Analisar o comportamento espectro-temporal das fitofisionomias do Cerrado por meio dos índices de vegetação advindos de dados orbitais e aerotransportados;
- Determinar a viabilidade de uso dos índices de vegetação do visível para monitoramento das fitofisionomias do Cerrado.

3 JUSTIFICATIVA

Embora as RPAs tenham sido criadas há décadas, seu potencial de aplicação em estudos científicos vem se mostrando cada vez mais promissor nos últimos anos, uma vez que a redução dos custos de aquisição e os desenvolvimentos tecnológicos fizeram com que esses equipamentos se tornassem cada vez mais comuns em todo o mundo. Do ponto de vista do sensoriamento remoto, as possibilidades de aquisição de imagens com altas resoluções espaciais, as flexibilidades operacionais e os custos inferiores às demais tecnologias existentes fazem destas plataformas uma alternativa cada vez mais viável para aquisição de dados da superfície terrestre (D'OLEIRE-OLTMANNNS et al., 2012; FANG et al., 2016).

Em meio aos muitos trabalhos científicos que utilizam as RPAs como plataforma de obtenção de informações, as pesquisas voltadas ao monitoramento das superfícies vegetais têm ganhado cada vez mais destaque no âmbito científico. Esses estudos buscam realizar basicamente uma série de investigações sobre as relações existentes entre as REM e as propriedades espectrais que as vegetações apresentam, sendo possível determinar algumas de suas características fisiológicas, biofísicas e bioquímicas por meio dos índices espectrais de vegetação (TURNER et al., 2012; PÔÇAS et al., 2015).

Apesar de muitos estudos utilizarem diferentes índices de vegetação, poucos avaliam as potencialidades dos índices baseados apenas na porção visível do espectro eletromagnético. Autores como Hunt-Jr et al. (2005), Zhu et al. (2009) e Córcoles et al. (2013) até investigaram algumas aplicações com esse tipo de índice, no entanto, os que utilizam as faixas espectrais do infravermelho ainda se mostram mais difundidos e robustos no monitoramento da vegetação. Porém, os sistemas sensores que captam as informações nesses comprimentos de onda ainda apresentam elevados custos de aquisição e não estão disponíveis para grande parte dos pesquisadores e potenciais usuários de todo o mundo (ZHENG et al., 2018).

Desta forma, o desenvolvimento de pesquisas que utilizam índices espectrais de vegetação baseados apenas na porção visível ganha cada vez mais importância e relevância no cenário científico atual. Essa importância se dá principalmente pelo fato de que os produtos advindos de RPAs convencionais equipados com câmeras RGB se constituem em uma possível fonte de dados, com grandes potencialidades de aplicação e inúmeras possibilidades no monitoramento ambiental.

4 REFERENCIAL TEÓRICO

Para um melhor entendimento e contextualização teórica das temáticas aqui abordadas, o referencial teórico foi elaborado englobando informações sobre: o desenvolvimento e a história do sensoriamento remoto; os fundamentos básicos dessa tecnologia; a utilização do sensoriamento remoto em análises sobre as características das vegetações e os fundamentos da aplicação de análises estatísticas sobre diferentes dados.

4.1 SENSORIAMENTO REMOTO

O sensoriamento remoto, termo criado por Evelyn L. Pruitt e Walter H. Bailey no início dos anos 1960, se constitui na ciência dotada de técnicas e métodos que possibilitam a obtenção de informações sobre diferentes alvos sem que aconteça a interação física entre o agente investigador e o objeto investigado. Reconhecido como um dos métodos de coleta de dados mais bem-sucedidos da história da humanidade, o sensoriamento remoto é amplamente utilizado em observações planetárias, ações de planejamento, monitoramento de recursos naturais, ações militares, entre outras aplicações (COLWELL, 1984; FUSSELL; RUNDQUIST; HARRINGTON-JR., 1986).

Com uma origem associada à criação dos equipamentos ópticos em 1839, juntamente ao primeiro registro fotográfico aéreo realizado em 1859, as teorias clássicas do eletromagnetismo (1854-1879), o aprimoramento da aerofotografia (1909), o desenvolvimento do radar (1930) e a criação dos sensores infravermelho (1940), apresentaram grande influência no desenvolvimento das tecnologias voltadas ao sensoriamento remoto, sendo são considerados como elementos fundamentais para formação dessa tecnologia. Porém, a grande revolução espacial ocorrida entre 1957 e 1975 permitiu que os primeiros satélites artificiais fossem enviados para o espaço com a finalidade de adquirir informações consistentes sobre o planeta Terra, dando origem assim ao sensoriamento remoto moderno amplamente reconhecido no mundo moderno atual (NOVO; PONZONI, 2001; AGGARWAL, 2004; MELESSE et al., 2007).

O satélite pioneiro a ser enviado ao espaço foi o rudimentar Sputnik-I, lançado em 1957 pela União das Repúblicas Socialistas Soviéticas (URSS) com o objetivo de testar a capacidade de transporte de cargas úteis ao espaço. Mas os primeiros passos dados pelo sensoriamento remoto foram proporcionados pelo satélite meteorológico *Television Infrared Operational Satellite* (TIROS-1) (Figura 1), lançado em 1960 pelos Estados Unidos da

América (EUA). Lançado com o objetivo avaliar as técnicas de observação da Terra, o TIROS-1 possibilitou que fossem realizados os primeiros registros da superfície terrestre com múltiplas possibilidades de análises meteorológicas. Já em 1972 foi a vez do *Earth Resources Technology Satellite* (ERTS-1) (Figura 2), o primeiro satélite lançado ao espaço com sensores capazes de fornecer dados para aplicações ambientais. Posteriormente, teve seu nome alterado para Landsat-1, sendo considerado como o primeiro satélite da série de mapeamento mais bem-sucedida da história (HOUSE et al., 1986; MELESSE et al., 2007).

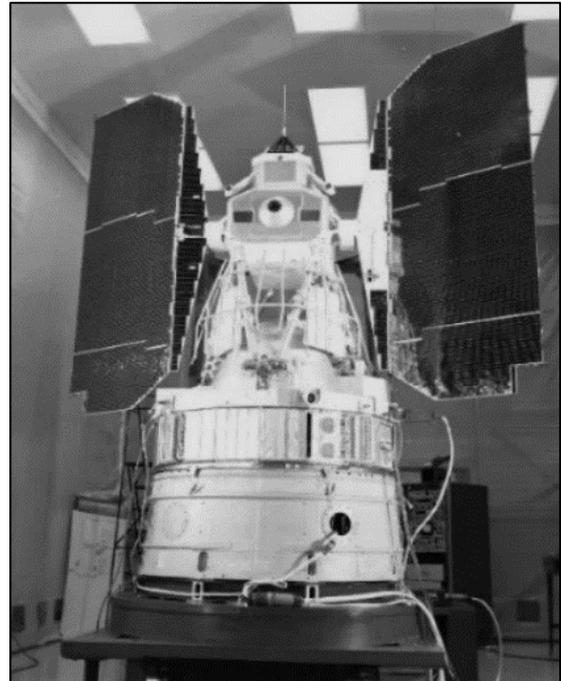
Atualmente acredita-se que exista entre 4.000 e 5.000 satélites orbitando o planeta Terra, adquirindo informações sobre diferentes alvos com múltiplas finalidades de análises. Além disso, os avanços tecnológicos empregados às tecnologias do sensoriamento remoto vêm permitindo o uso de RPA como fonte de dados para aplicação em análises no âmbito ambiental, científico, civil, comercial e industrial (FLORENZANO, 2008; CÂNDIDO; SILVA; PARANHOS-FILHO, 2015; SOUSA, 2017).

Figura 1 - TIROS-1



Fonte: Nasa (2010)

Figura 2 - ERTS-1



Fonte: Smithsonian (1971)

4.2 FUNDAMENTOS DO SENSORIAMENTO REMOTO

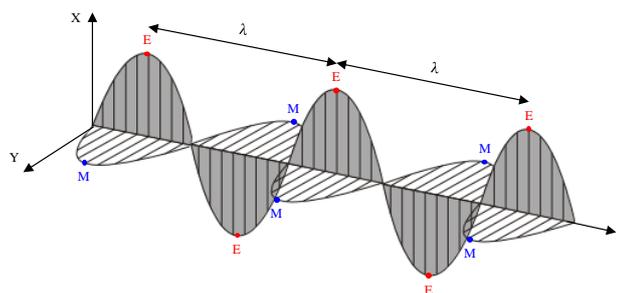
Para que ocorra uma melhor compreensão dos fundamentos básicos do sensoriamento remoto, é necessário que ocorra uma compreensão das REM e suas características, das propriedades das REM ao interagir com os alvos terrestres e os diferentes tipos de sistemas sensores existentes.

4.2.1 RADIAÇÃO ELETROMAGNÉTICA (REM)

Definida como a energia produzida por meio das variações temporais dos campos elétricos e magnéticos, a REM pode ser emitida por fontes naturais e/ou artificiais, atingindo uma velocidade de propagação próxima à da luz, com frequências medidas em hertz (Hz) e comprimentos de onda medidos em metros (m) e seus submúltiplos. Suas interações com o meio físico são consideradas o princípio básico para o sensoriamento remoto, tendo em vista que seu comportamento de propagação pode ser explicado pelos modelos ondulatório e corpuscular (NOVO; PONZONI, 2001; MENESES, 2012; ABREU; COUTINHO, 2014).

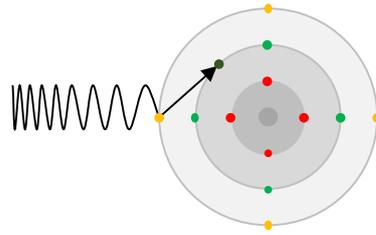
Pela perspectiva ondulatória, a REM é definida como uma onda senoidal harmônica, formada pelas vibrações e oscilações dos campos elétricos e magnéticos (Figura 3). Por outro lado, na visão corpuscular a REM é estabelecida como uma forma dinâmica de energia, que se manifesta por meio de transferências eletrônicas entre a energia e a matéria (Figura 4). Em resumo, pode-se dizer que para o modelo ondulatório as interações acontecem entre a REM e as propriedades físicas dos objetos (interação macroscópica), enquanto que para o modelo corpuscular essas interações são com as propriedades químicas dos objetos (interação microscópica) (NOVO; PONZONI, 2001; MENESES, 2012; ABREU; COUTINHO, 2014).

Figura 3 - Direção de propagação da REM (X, Y, Z) na forma de onda em função das oscilações do campo magnético (M) e elétrico (E) e comprimento de onda (λ)



Fonte: Adaptado de Menezes (2012)

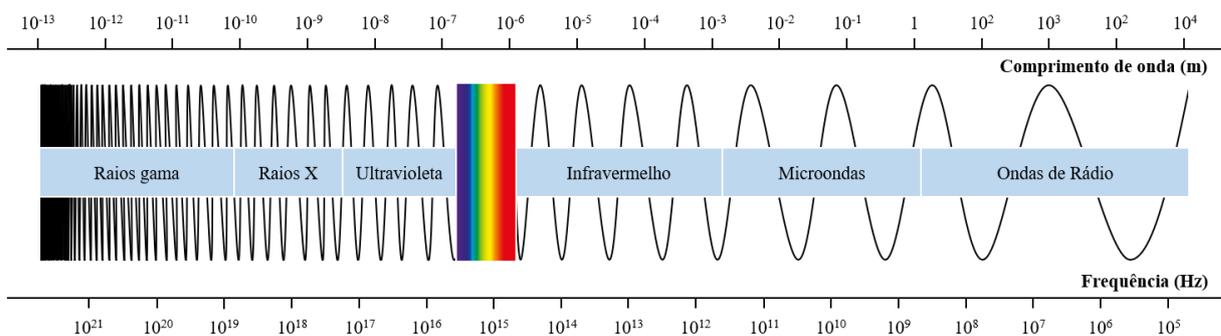
Figura 4 - Absorção da REM com deslocamento de elétrons para orbitais com maior energia



Fonte: Adaptado de Meneses (2012)

O conjunto das REM pode ainda ser ordenado de maneira contínua em função de suas características de comprimento de onda ou frequências. Esta disposição, denominada como espectro eletromagnético, se constitui em uma representação didática dos agrupamentos das REM conforme os mecanismos físicos geradores e detectores de energia. Suas principais divisões podem ser observadas na Figura 5, uma representação ilustrativa, onde é possível observar os padrões de comportamento das REM, cujas ondas de alta frequência apresentam comprimentos curtos e as ondas de baixa frequência apresentam comprimentos longos (FLORENZANO, 2002; WENG, 2010; MOREIRA, 2011; MENESES, 2012).

Figura 5 - Espectro eletromagnético



Fonte: Adaptado de Florenzano (2002)

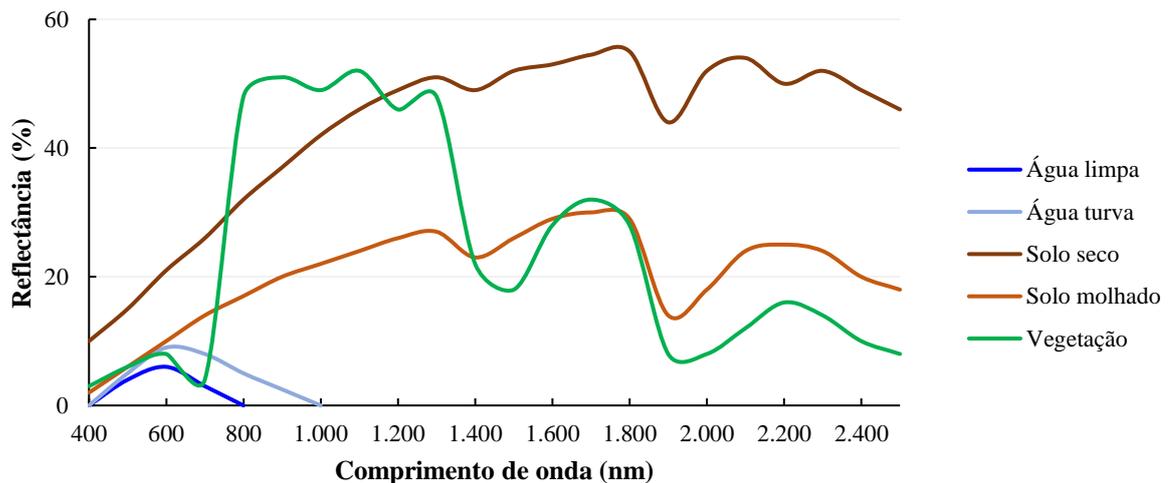
4.2.2 COMPORTAMENTO ESPECTRAL DOS MATERIAIS

Sabe-se que pelo princípio da conservação da energia, quando as REM incidem sobre os materiais terrestres, elas têm parte de sua composição refletida por sua superfície, parte absorvida pelos átomos e parte transmitida caso o objeto apresente características de transparência. Para muitos dos sistemas sensores que operam nas faixas ópticas, o comportamento espectral dos objetos é codificado a valores da REM refletida. Dessa forma, as intensidades dessas radiações são designadas pelo termo reflectância e podem ser definidas

nos múltiplos comprimentos de onda, caracterizando, assim, o comportamento espectral dos objetos (SLATER, 1980; MENESES, 2001).

Moreira (2011) afirma que conhecendo o comportamento espectral dos diferentes alvos da superfície terrestre é possível identificar alvos semelhantes apenas por suas características espectrais. Para a vegetação, as características espectrais variam conforme o comprimento de onda, uma vez que os pigmentos vegetais absorvem fortemente a radiação nos comprimentos de onda vermelho e azul, mas reflete o comprimento de onda verde e infravermelho. Quanto à água, a maior parte da radiação incidente não é refletida e sim absorvida ou transmitida, tendo a profundidade, os materiais em suspensão e a rugosidade como os principais fatores que afetam a sua variabilidade espectral. Já para os solos, a maior parte da radiação incidente na superfície é refletida ou absorvida com uma baixa taxa de transmissão, tendo os teores de umidade, o teor de matéria orgânica, o teor de óxido de ferro, as texturas e suas estruturas como fatores que influenciam em suas propriedades espectrais. Para um melhor entendimento dessas interações, a Figura 6 apresenta o comportamento espectral de alguns dos mais importantes alvos terrestres nos comprimentos de onda entre 400 a 2.500 nm (AGGARWAL, 2004).

Figura 6 - Comportamento espectral para a água limpa e turva, solo seco e molhado e vegetação

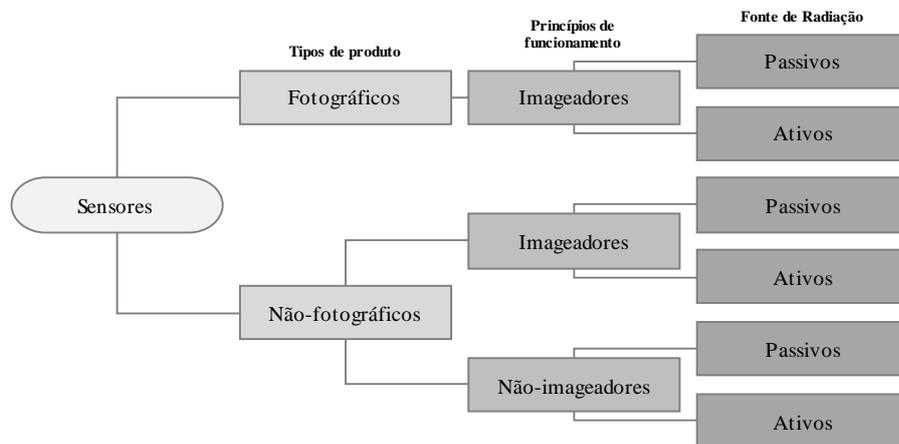


Fonte: Adaptado de Aggarwal (2004)

4.2.3 SISTEMAS SENSORES

Para que os comportamentos espectrais de cada alvo sejam estudados, é necessário que existam equipamentos com capacidades suficientes para captar as informações espectrais inerentes a cada um dos objetos. Nesse sentido, os sistemas sensores são caracterizados como todo e qualquer dispositivo que detectam e registram as REM em determinadas faixas do espectro eletromagnético, apresentando a capacidade de transformar essas informações em produtos passíveis de interpretação. Esses equipamentos são comumente acoplados em plataformas de deslocamento, seja ao nível terrestre (radiômetros ou espectroradiômetros), sub-orbital (aviões, drones, etc.) e orbital (satélites artificiais), sendo classificados conforme os produtos gerados, princípios de funcionamento e origem da fonte energética (Figura 7) (VIECILI, 2005; MAIO et al., 2008; NOVO, 2010; ABREU; COUTINHO, 2014; MOREIRA, 2011).

Figura 7 - Classificação dos sistemas sensores



Fonte: Adaptado de Moreira (2011)

Os sistemas sensores são normalmente divididos em sistemas não-fotográficos e fotográficos, sendo a principal diferença entre eles aquela relacionada com a forma com que se dá o registro das REM. Para os sensores não-fotográficos, esses equipamentos possuem detectores que transformam as REM em sinais elétricos, enquanto os fotográficos registram as REM de maneira contínua e analógica, em um processo de natureza foto-química, sobre um filme. Quanto aos princípios de funcionamento, os sistemas sensores são divididos em sistemas imageadores e não-imageadores, visto que nos sistemas imageadores as informações referentes às REM são expressas por imagens, enquanto os não-imageadores apresentam

informações em formato de gráficos e números. Já para as suas fontes de radiação, os sistemas sensores são divididos entre sensores passivos e ativos, sendo os sensores passivos não detentores de emissores de REM próprio, enquanto os sensores ativos dispõem de sua própria fonte de REM (NOVO; PONZONI, 2001; VIECILI, 2005; NOVO, 2010; MOREIRA, 2011).

A qualidade dos produtos gerados pelos sistemas sensores está diretamente relacionada às suas características de resoluções espacial, espectral, radiométrica e temporal. A resolução espacial representa a capacidade de distinção dos objetos captados pelos sensores, indicando o tamanho do menor elemento da superfície que pode ser individualizado. A resolução espectral refere-se especificamente à largura do espectro eletromagnético com que cada banda do sensor opera. A resolução radiométrica define a eficiência do sistema em detectar e registrar as diferenças de energia refletida e/ou emitida. E a resolução temporal está relacionada diretamente com a repetitividade com que o sensor pode adquirir as informações sobre o mesmo objeto (MORAES, 2002; MAIO et al., 2008; SHIMABUKURO; MAEDA; FORMAGGIO, 2009).

A seguir serão detalhados os sistemas sensores utilizados no desenvolvimento da pesquisa, sendo um sistema sensor convencional RGB acoplado a uma RPA quadricóptero, e outro sensor multiespectral embarcado nos satélites da missão Sentinel-2, ambos caracterizados como sistemas sensores não-fotográficos imageadores passivos.

4.2.3.1 AERONAVES REMOTAMENTE PILOTADAS (RPA)

Apesar das definições para os termos RPA, veículo aéreo não tripulado (VANT) e drone ainda estarem abertas aos debates, esses equipamentos se caracterizam como toda e qualquer aeronave de asa fixa ou multirotor que não necessite de piloto embarcado para guiá-la. Podem ser diferenciadas quanto às suas finalidades, tipos, variedade de tamanho, carga útil, raio de alcance, altitude de voo e têm permitido a obtenção de dados para estudos científicos em diferentes áreas do conhecimento (NEWCOME, 2004; HARDIN; JENSEN, 2011).

Tal como o ocorrido com diversas outras tecnologias, as RPAs foram inicialmente empregadas em missões militares e estão sendo cada vez mais utilizadas no âmbito do entretenimento e em aplicações profissionais. Dentre as possibilidades de aplicação, o sensoriamento remoto ambiental tem demonstrado resultados extremamente promissores ao utilizá-las, com pesquisadores de todo o mundo investigando as suas aplicações e buscando respaldo científico para a continuidade de uso destes dispositivos (TOMLINS, 1983;

NYQUIST, 1996; QUILTER; ANDERSON, 2016).

Suas principais vantagens quando comparados a sistemas imageadores convencionais são: altas resoluções espaciais e temporais; potencial para produção de imagens tridimensionais; preços relativamente baixos e possibilidade de acesso a áreas inacessíveis. Quanto às suas desvantagens, podem ser mencionadas: a pequena carga útil (*payload*); baixa resolução espectral; sensibilidade às condições atmosféricas; possibilidade de colisões e quedas; problemas potenciais de manutenção; aspectos legais e questões de segurança e proteção (PANEQUE-GÁLVEZ et al., 2014).

Dentre os modelos disponíveis no mercado, o quadricóptero Phantom 4 (Figura 8) fabricado pela empresa DJI recebe uma atenção especial por ter sido utilizado nesta pesquisa. Este equipamento contém uma câmera convencional RGB integrada ao seu esqueleto com sensor óptico 1/2.3" CMOS de 12.4 megapixels, lentes 20mm, f/2.8 e campo de visada (FOV) de 94° e GPS/GLONASS para auxílio na navegação (DJI, 2016; HARDIN et al., 2018).

Figura 8 - Quadricóptero Phantom 4



Fonte: DJI (2016)

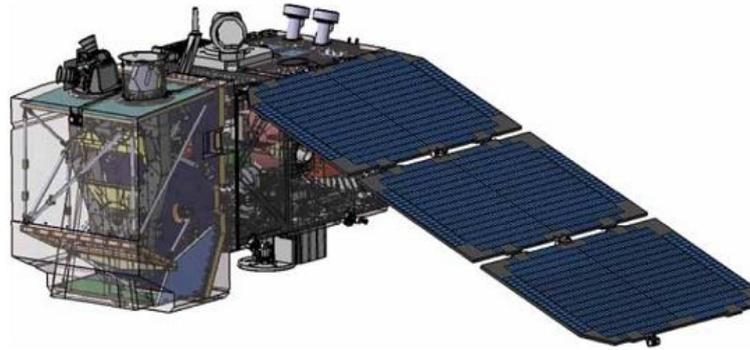
Temas como agricultura de precisão (BERNI et al., 2009b; HUNT-JR et al., 2011b; ZHANG; KOVACS, 2012); monitoramento da vegetação (BOOTH; COX, 2011; BRECKENRIDGE et al., 2011; LALIBERTE et al., 2011; RANGO et al., 2006, 2009), monitoramento da biodiversidade (JONES-IV; PEARLSTINE; PERCIVAL, 2006; WATTS et al., 2010; GETZIN; WIEGAND; SCHÖNING, 2012; RODRÍGUEZ et al., 2012; SARDÀ-PALOMERA et al., 2012), monitoramento de *habitats* (WUNDRAM; LÖFFLER, 2008; HERVOUET et al., 2011) e levantamentos topográficos (ZHANG, 2006; CORBANE et al., 2012; EISENBEISS), dentre outros assuntos, passaram a empregar em seu desenvolvimento os dados advindos desse tipo de RPA.

4.2.3.2 SENTINEL-2

A Agência Espacial Europeia (ESA), em conjunto com a Comissão Europeia de Monitoramento Global do Ambiente e Segurança (GMES), estabeleceu por meio do Regulamento Europeu nº 377/2014, a criação do programa Copernicus para dar continuidade à iniciativa de monitoramento do planeta Terra, regulamentada pelo decreto Europeu nº 911/2010. Esse programa foi criado com o objetivo de alcançar uma ampla capacidade de observação terrestre, oferecendo aos usuários do sensoriamento remoto o acesso autônomo e confiável a uma grande diversidade de dados para proteção da sociedade civil e do meio ambiente (EU, 2010, 2014; ESA, 2019a, 2019b).

Entre as missões pertencentes ao programa Copernicus, a missão Sentinel-2 foi projetada especificamente para atender as necessidades de imageamento da superfície terrestre, tendo como principal objetivo o desenvolvimento do imageamento multiespectral da superfície terrestre com alta resolução espacial e temporal para monitoramentos da vegetação, da cobertura do solo, dos recursos hídricos e das áreas costeiras. Além disso, a missão Sentinel-2 trouxe consigo a responsabilidade de dar continuidade à série de imageamento SPOT 4/5 e complementar as observações realizadas pela missão Landsat (DRUSCH et al., 2012; ESA, 2010a, 2010b, 2019a).

Constituída por uma constelação de dois satélites gêmeos, o Sentinel-2A (S2A) e Sentinel-2B (S2B) (Figura 9), foram lançados ao espaço em 23 de junho de 2015 e 7 de março de 2017, respectivamente. Ambos operam simultaneamente desde meados de 2017, com uma separação de 180°, órbita polar síncrona ao sol, altitude média de 786 km e recobrimento de toda a superfície terrestre entre as faixas de latitude de 56° Sul (Cabo Horn e América do Sul) e 84° Norte (acima da Groenlândia). Suas vidas úteis estão estimadas em aproximadamente 7,25 anos de operação, com baterias e propelentes capazes de acomodar 12 anos de operação, incluindo as manobras de decaimento ao final da vida útil (DRUSCH et al., 2012; ESA, 2010a, 2010b, 2019a).

Figura 9 - Imagem ilustrativa dos satélites S2A e S2B

Fonte: ESA (2019a)

Os instrumentos multiespectrais (MSI) embarcados em ambos os satélites são idênticos e utilizam o sistema de varredura do tipo *push-broom*, com uma largura de imageamento de 290 km. As REM são captadas de modo passivo, com resoluções espaciais de 10, 20 e 60 metros em 13 canais espectrais, que vão dos comprimentos de onda do visível até o SWIR. A temporalidade média de revisita é de cinco dias e os dados são fornecidos com uma radiometria de 12-bits. A Tabela 1 apresenta um resumo das características das bandas espectrais de ambos os sensores (DRUSCH et al., 2012; ESA, 2010a, 2010b, 2019a).

Tabela 1 - Características dos sensores MSI embarcados nos satélites S2A e S2B

Resolução Espacial(m)	Banda	Nome	S2A		S2B	
			Comprimento central (nm)	Largura da banda (nm)	Comprimento central (nm)	Largura da banda (nm)
10	B02	Blue	496,60	98,00	492,10	98,00
	B03	Green	560,00	45,00	559,00	46,00
	B04	Red	664,50	38,00	665,00	39,00
	B08	NIR	835,10	145,00	833,00	133,00
20	B05	Red Edge 1	703,90	19,00	703,80	20,00
	B06	Red Edge 2	740,20	18,00	739,10	18,00
	B07	Red Edge 3	782,50	28,00	779,70	28,00
	B08a	Red Edge 4	864,80	33,00	864,00	32,00
	B11	SWIR 1	1613,70	143,00	1610,40	141,00
	B12	SWIR 2	2202,40	242,00	2185,70	238,00
60	B01	Aerosol	443,90	27,00	442,30	45,00
	B09	Water Vapor	945,00	26,00	943,20	27,00
	B10	Cirrus	1373,50	75,00	1376,90	76,00

Fonte: ESA (2019a)

Os produtos de ambos os satélites disponibilizados aos usuários de forma gratuita pelo endereço eletrônico do Copernicus e pelo Serviço Geológico dos Estados Unidos (USGS) (ESA, 2019c; USGS, 2019). Estes dados apresentam nível de processamento Level-1C (L1C), caracterizado por reflectâncias do topo da atmosfera (TOA) com correções geométricas dos registros multiespectrais e sem nenhuma correção para as interferências atmosféricas (DRUSCH et al., 2012; ESA, 2010a, 2010b, 2019a; USGS, 2019).

O potencial de aplicação destes produtos vem se mostrando cada vez mais vantajoso quando comparado a outros satélites já consolidados, uma vez que foi projetado com melhores características que os demais (LIU et al., 2018). Temas como a aplicação de índices de vegetação (HILL, 2013), estudos geológicos (VAN DER MEER; VAN DER WERFF; VAN RUITENBEEK, 2014; VAN DER WERFF; VAN DER MEER, 2015), estudos arqueológicos (AGAPIOU et al., 2014), mapeamentos de uso e ocupação do solo (BORRÀS et al., 2017), mapeamentos de recifes de corais (HEDLEY et al., 2012), estimativas de parâmetros biofísicos (FRAMPTON et al., 2013), de teores de clorofila e nitrogênio foliar (CLEVERS; GITELSON, 2013), de índice de área foliar (IAF) (ATZBERGER; RICHTER, 2012; RICHTER et al., 2009, 2012), de qualidade da água (SALAMA; RADWAN; VAN DER VELDE, 2012), entre outros temas, vêm sendo cada vez mais pesquisados com esses dados por cientistas do mundo todo.

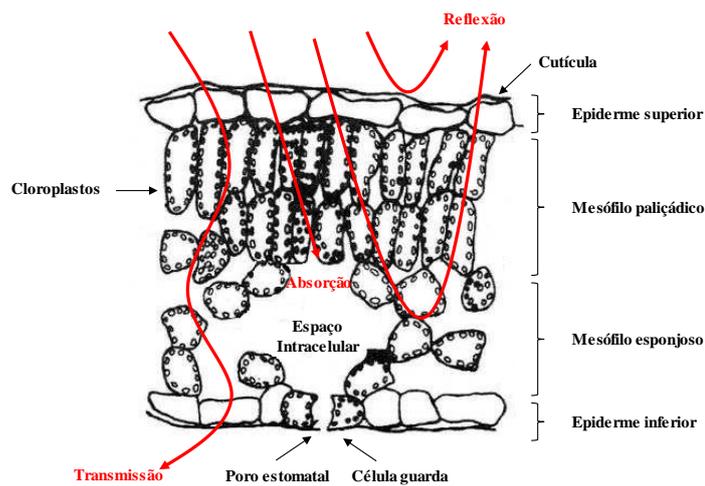
4.3 SENSORIAMENTO REMOTO DA VEGETAÇÃO

Desde a descoberta de que os vegetais extraem parte da energia presente nas radiações emitidas pelo Sol, as interações entre as REM e a vegetação passaram a ser tema de estudo em todo o mundo. Dentre as tecnologias utilizadas para essas investigações, o sensoriamento remoto foi a que mais contribuiu e que vem contribuindo com o conhecimento da área. Além de propiciar o mapeamento de grandes áreas da superfície terrestre, o sensoriamento remoto também viabilizou estudos sobre a vegetação em função de suas características fisionômicas, florísticas e fitoecológicas (PONZONI, 2001; SHIMABUKURO; MAEDA; FORMAGGIO, 2009).

Há que se considerar que os estudos vegetais atrelados ao uso do sensoriamento remoto avaliam uma série de fatores vegetais e principalmente o ambiente que se encontram a vegetação. Contudo, a principal motivação destes estudos se dá pela necessidade de tentar compreender e explicar o comportamento que os vegetais assumem ao interagir com os diferentes comprimentos de onda (BOHRER, 2000; PONZONI, 2002 ;BOHRER et al., 2009).

Entre os componentes da vegetação, as folhas são consideradas como o principal elemento de interação das plantas com a energia eletromagnética. Na literatura existem muitos trabalhos relacionados à determinação das propriedades espectrais das plantas nas faixas espectrais ópticas, tendo a revisão sobre os processos de interação vegetal com as REM publicado por Kumar (1972) como destaque. A Figura 10 apresenta um corte transversal em uma folha, onde são apresentados os seus principais componentes e os possíveis comportamentos das REM incidente, segundo Ponzoni e Shimabukuro (2007).

Figura 10 - Estruturas interna de uma folha com possíveis comportamentos da REM incidente



Fonte: Adaptado de Ponzoni e Shimabukuro (2007)

É possível observar que as folhas são constituídas por diferentes tecidos, sendo a face ventral a parte que recebe a maior quantidade de REM, com pelos e uma camada de cera (cutícula) como estruturas de proteção para essas respectivas exposições. Logo abaixo se encontra a epiderme, composta geralmente por células alongadas e diferenciadas por funções, como os estômatos. Abaixo da epiderme encontra-se o mesófilo paliádico, o qual é organizado por células ricas em cloroplastos, que se caracterizam por organelas nas quais se encontram pigmentos fotossintetizantes, como a clorofila. Seguindo a direção dorsal, encontra-se o mesófilo esponjoso, cuja organização celular é menos compacta e apresenta lacunas entre as células, preenchidas pelos gases resultantes da respiração e transpiração celular. Novamente segue a epiderme com um número frequentemente maior de estômatos, e finalmente uma nova camada de cera e cutículas (PONZONI; SHIMABUKURO, 2007).

Quanto ao comportamento das REM ao interagir com a vegetação, de forma generalista, entende-se que as REM assumem caráter de reflexão ao entrar em contato com a cutícula, com parte de absorção da energia realizada pelas células fotossintetizantes do

mesófilo paliçádico, parte espalhada nos espaços intracelulares do mesófilo esponjo e uma transmitida para as camadas inferiores (PONZONI; SHIMABUKURO, 2007; MOREIRA, 2011; ABREU; COUTINHO, 2014). Quanto aos principais aspectos relacionados ao comportamento espectral que as REM assumem ao interagir com a vegetação, Ponzoni (2001) define que:

- **Região do visível** - Os pigmentos existentes nas folhas dominam a reflectância espectral. Esses pigmentos, geralmente encontrados nos cloroplastos, são a clorofila (65%), xantofilas (29%) e carotenos (6%), com valores percentuais variando conforme as diferentes espécies. A energia radiante interage com a estrutura foliar nessa faixa espectral por absorção e espalhamento, tendo a energia absorvida pela clorofila convertida fotoquimicamente em energia estocada, essencial para a fotossíntese;
- **Região do NIR** - Nesta região existe absorção das REM e considerável espalhamento interno nas folhas, resultado da interação da energia incidente com a estrutura do mesófilo. Fatores externos à folha, como disponibilidade de água, podem causar alterações no fator água/ar no mesófilo e alterar as reflectâncias vegetais nessa faixa do espectro;
- **Região do SWIR** - As REM nessa faixa espectral são praticamente toda absorvidas e, conseqüentemente, apresenta pequena reflectância.

4.3.1 ÍNDICES DE VEGETAÇÃO

Identificada como uma das mais simples e eficientes formas de análise da vegetação, os índices espectrais de vegetação, ou simplesmente índices de vegetação, são definidos como um dos subprodutos do sensoriamento remoto, com grande aplicabilidade no monitoramento da dinâmica das coberturas vegetais (FERREIRA; FERREIRA; FERREIRA, 2008; AMRI et al., 2011). Seus resultados se configuram em medidas radiométricas adimensionais obtidas por meio de combinações aritméticas de bandas espectrais para monitoramento de parâmetros como: IAF, porcentagem de cobertura verde, teor de clorofila, biomassa verde, entre outros (LIU; HUETE, 2003; JENSEN, 2009; WANG).

A fundamentação teórica de sua utilização reside no fato de que o comportamento das reflectâncias nas regiões espectrais do VNIR está diretamente relacionado às atividades fotossintéticas da vegetação (PONZONI; SHIMABUKURO, 2007). Vale ressaltar que os procedimentos de elaboração dos índices reduzem drasticamente os ruídos que afetam as respostas espectrais da vegetação, cujas interferências estão relacionadas às variações na

irradiância solar; efeitos atmosféricos; contribuições da vegetação não-fotossinteticamente ativa e dos efeitos advindos da composição e estrutura dos dosséis (MENESES, 2001; ZANZARINI et al., 2013).

Dentre os diversos índices presentes na literatura, o índice de vegetação da diferença normalizada (NDVI), o índice de vegetação de folha verde (GLI), o índice de vegetação da diferença normalizada do verde e vermelho (NGRDI) e o índice de vegetação com resistência atmosférica ao visível (VARI) ganham destaque e serão detalhados a seguir.

4.3.1.1 ÍNDICE DE VEGETAÇÃO DA DIFERENÇA NORMALIZADA (NDVI)

Desenvolvido por Rouse et al. (1974) como uma proposta de modificação para o índice de razão simples (SR) proposto por Jordan (1969), o *Normalized Difference Vegetation Index* se caracteriza como um índice formado pela diferença normalizada das reflectâncias das bandas do NIR e vermelho (Equação 1). Sua simplicidade de aplicação e relativa sensibilidade de identificação de coberturas vegetais permitiram a sua utilização para inúmeras análises sob a atividade fotossintética. Embora seja considerada a métrica mais bem sucedida para análise da vegetação no meio acadêmico, sua interpretação deve levar em consideração seus fatores limitantes, como: a saturação de pixels em áreas densas, a geometria de aquisição sol-alvo-sensor e as interferências de fatores externos (HUETE, 1988; HUETE et al., 1997; PONZONI; SHIMABUKURO, 2007; FERREIRA; FERREIRA; FERREIRA, 2008; JENSEN, 2009).

$$NDVI = \frac{(NIR - R)}{(NIR + R)} \quad \text{(Equação 1)}$$

Em que:

R: valor de reflectância na faixa espectral do vermelho;

NIR: valor de reflectância na faixa espectral do NIR.

4.3.1.2 ÍNDICE DE VEGETAÇÃO DE FOLHA VERDE (GLI)

Elaborado por Louhaichi, Borman e Johnson (2001) com o objetivo de determinar a intensidade de degradação da vegetação por fotografia aérea, o *Green Leaf Index* é um índice de vegetação formado pela diferença normalizada das reflectâncias das faixas espectrais do

azul, verde e vermelho (Equação 2). Louhaichi, Borman e Johnson (2001) acreditam que a utilização deste índice tem potencial promissor de aplicação para análises vegetais, uma vez que apresentou resultados satisfatórios para avaliação da fração da vegetação. Autores como Hunt-Jr et al. (2011a) e Ballesteros et al. (2018) afirmam que o GLI apresenta resultados robustos para avaliação da vegetação, podendo ser utilizado como fator indicativo de degradação vegetal, já que apresentaram boas correlações com alterações na clorofila foliar.

$$GLI = \frac{(2 * G - R - B)}{(2 * G + R + B)} \quad \text{(Equação 2)}$$

Em que:

B: valor de reflectância na faixa espectral do azul;

G: valor de reflectância na faixa espectral do verde;

R: valor de reflectância na faixa espectral do vermelho.

4.3.1.3 ÍNDICE DE VEGETAÇÃO DA DIFERENÇA NORMALIZADA DO VERDE E DO VERMELHO (NGRDI)

O *Normalized Green Red Difference Index* foi um índice proposto por Tucker (1979) após Kanemasu (1974) concluir que as faixas espectrais do verde e do vermelho podem servir como indicador de crescimento e desenvolvimento das plantas. É um índice elaborado pela diferença normalizada das reflectâncias das bandas espectrais do verde e do vermelho (Equação 3), sendo geralmente utilizado para estimar a fração de vegetação, biomassa verde e indicador de fenologias vegetais. Dentre alguns trabalhos utilizando esse índice, Hunt et al. (2005) apresenta resultados que demonstram uma alta correlação entre os seus resultados e os valores de biomassa verde. Já Wan et al. (2018) demonstra em sua pesquisa altas correlações deste índice com o número de flores em campos de girassóis na China, demonstrando sua alta aplicabilidade em realizar estimativas sobre as vegetações.

$$\text{NGRDI} = \frac{(G - R)}{(G + R)} \quad (\text{Equação 3})$$

Em que:

G: valor de reflectância na faixa espectral do verde;

R: valor de reflectância na faixa espectral do vermelho.

4.3.1.4 ÍNDICE DE VEGETAÇÃO COM RESISTÊNCIA ATMOSFÉRICA AO VISÍVEL (VARI)

Elaborado por Gitelson et al. (2002) como uma modificação para o NGRDI, o *Visible Atmospherically Resistant Index* foi proposto por apresentar baixa sensibilidade aos efeitos atmosféricos e resultados satisfatórios na estimativa da fração da vegetação. Este índice utiliza em sua formulação as faixas espectrais do azul, verde e vermelho, com detalhe quanto à subtração da banda azul no denominador, proposta para reduzir os efeitos atmosféricos (Equação 4) (KAUFMAN; TANRÉ, 1992). Gitelson et al. (2003) afirma que o comportamento do VARI ao avaliar o índice da área foliar é bastante diferente do NDVI, uma vez que seu comportamento temporal segue as variações proporcionadas pelo ciclo fenológico da vegetação. Fang et al. (2016) afirma também que as estimativas sobre a vegetação com este índice estão estritamente ligadas às variações fenológicas presentes no seu ciclo de desenvolvimento.

$$\text{VARI} = \frac{(G - R)}{(G + R - B)} \quad (\text{Equação 4})$$

Em que:

B: valor de reflectância na faixa espectral do azul;

G: valor de reflectância na faixa espectral do verde;

R: valor de reflectância na faixa espectral do vermelho.

5 MATERIAIS E MÉTODOS

Para que os objetivos propostos pela pesquisa fossem atingidos, ela foi dividida em 4 etapas distintas. A primeira etapa consistiu no planejamento e organização de todo o estudo, sendo definidos os objetivos e os detalhes metodológicos que seriam empregados em seu decorrer. Já a segunda etapa consistiu em um conjunto de revisões bibliográficas das temáticas abordadas, procurando-se obter o embasamento teórico necessário para o desenvolvimento da pesquisa. Quanto à terceira etapa, essa compreendeu na aquisição, processamento e análise dos conjuntos de dados utilizados, sendo empregados todos os detalhes metodológicos definidos anteriormente. Por fim, a quarta e última etapa consistiu em analisar e discutir todos os resultados obtidos, elaborando assim as respectivas conclusões pertinentes ao estudo.

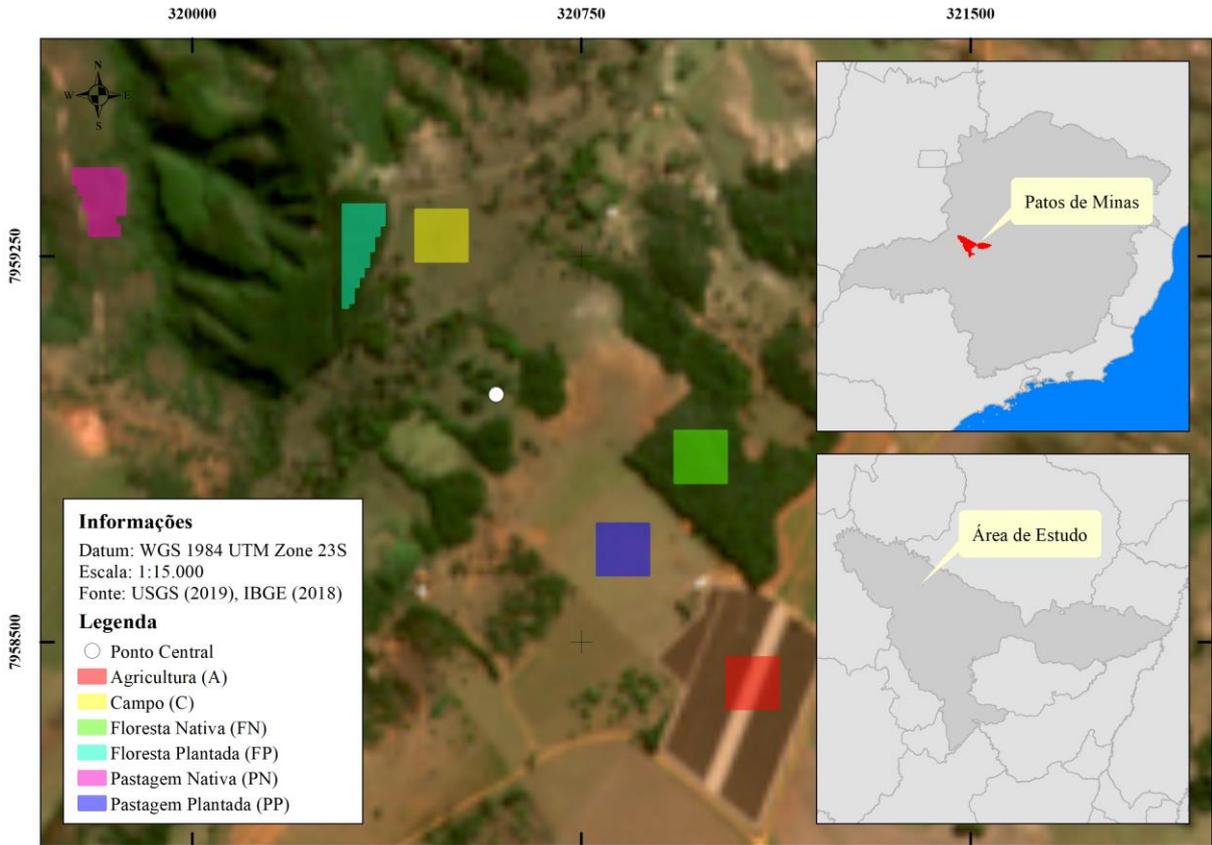
5.1 ÁREA DE ESTUDO

Localizada no município de Patos de Minas/Minas Gerais, a área de estudo está localizada em um raio de 950 metros partindo da coordenada geográfica de latitude 18° 27' 07" Sul e longitude 46° 41' 56" Oeste (Figura 11). Segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE), o município de Patos de Minas está situado nas regiões intermediárias do Triângulo Mineiro e Alto Paranaíba com a 27° maior extensão territorial do estado com 3.190,19 km² e a 16° maior população com 150.833 habitantes (IBGE, 2018).

A Figura 11 apresenta também a distribuição espacial das parcelas amostrais localizadas na área de estudo, sendo essas situadas em diferentes fitofisionomias do bioma Cerrado com características e formações vegetais totalmente distintas. Com uma área total de análise de 60.000 m², seis parcelas amostrais com 10.000 m² foram propostas para análise da vegetação por possibilitarem a captura de informações sobre diferentes localidades com coberturas vegetais homogêneas e estado de conservação distintos.

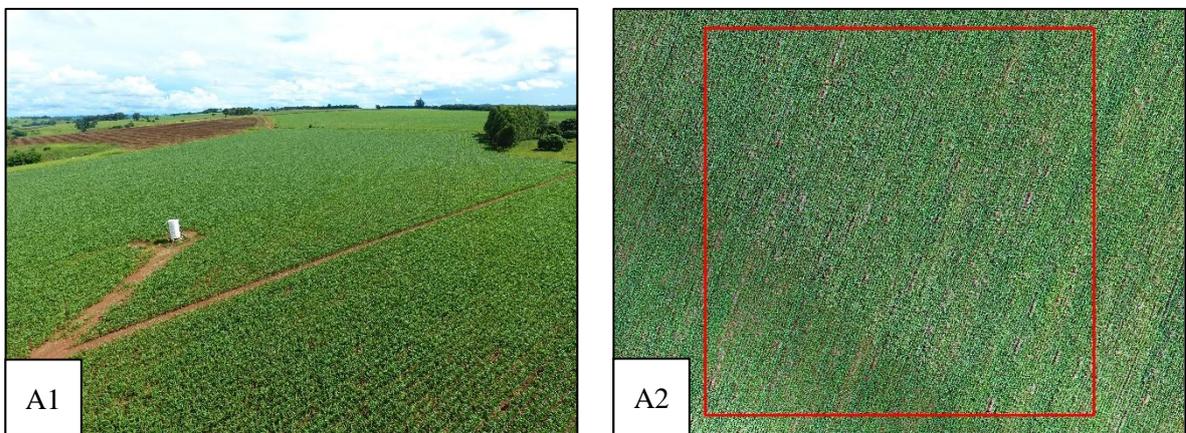
A Figura 12 apresenta a situação e estrutura da vegetação em cada uma das parcelas propostas, sendo: uma parcela formada por agricultura (A) de milho-verde (*Zea mays*), três parcelas com formações campestres com extrato herbáceo-arbustivo de campo (C), pastagem nativa (PN) e pastagem plantada (PP) e duas parcelas com formações florestais com extrato arbóreo de floresta nativa (FN) e floresta plantada (FP) com eucalipto (*Eucalyptus cloeziana*) (RIBEIRO; WALTER, 1998).

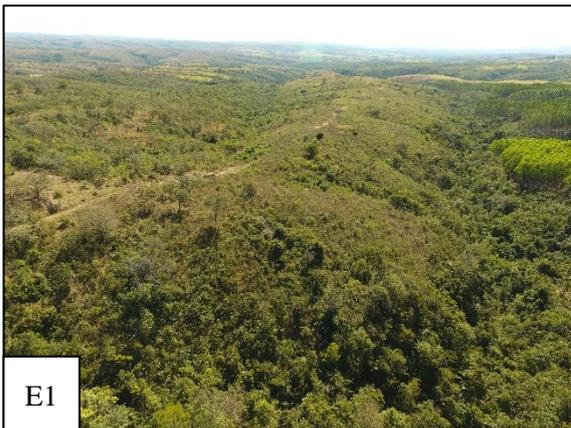
Figura 11 - Localização da área de estudo e das parcelas amostrais

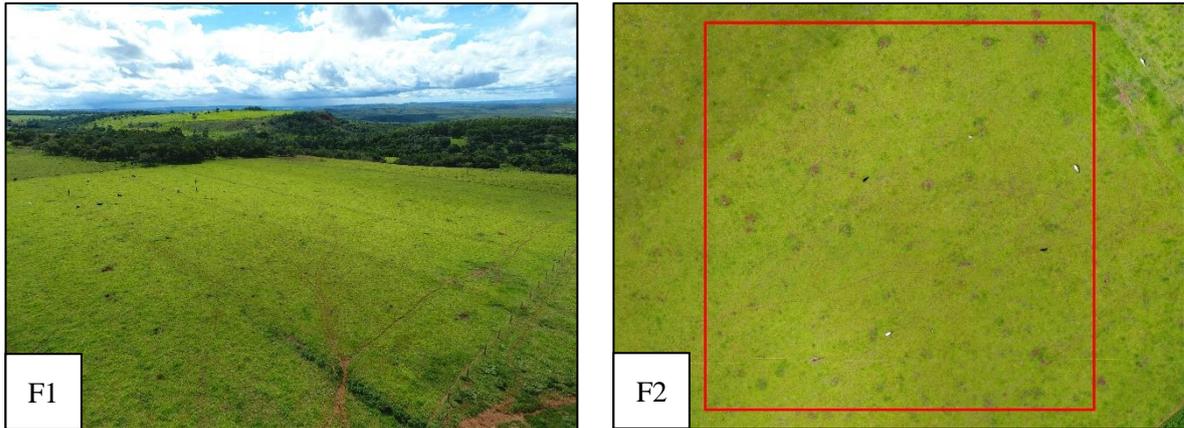


Fonte: Autor (2019)

Figura 12 - (A1, A2) Agricultura; (B1, B2) campo; (C1, C2) floresta nativa; (D1, D2) floresta plantada; (E1, E2) pastagem nativa; (F1, F2) pastagem plantada



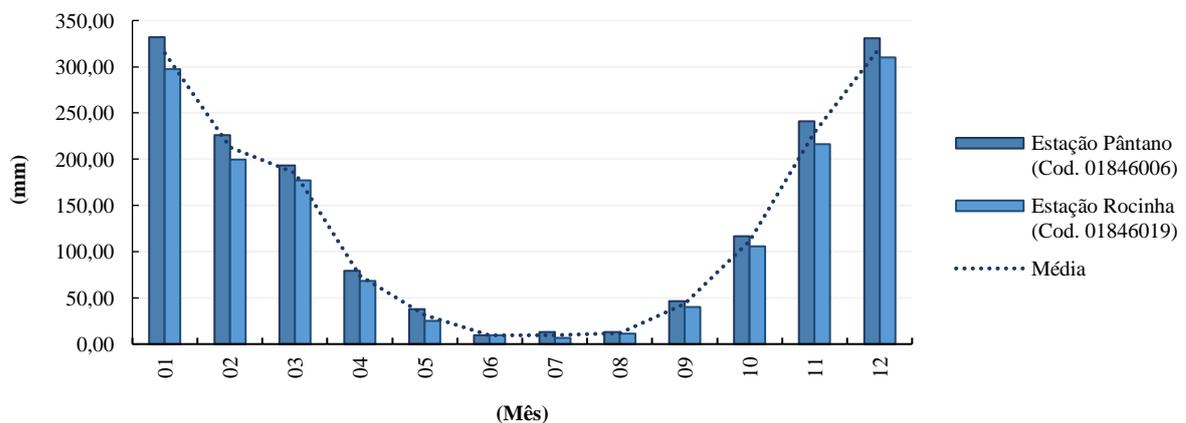




Fonte: Autor (2019)

Do ponto de vista climático, o clima local é definido como tropical de características savânicas, onde o verão apresenta elevadas temperaturas com baixa umidade e o inverno apresenta baixas temperaturas com alta umidade (KÖPPEN, 1923). As precipitações regionais variam entre 1.400 a 1.600 mm/ano, com sazonalidades pluviométricas bem definidas e marcantes entre períodos secos (maio a setembro) e períodos chuvosos (outubro a abril), como é mostrado na Figura 13 (ANA, 2019).

Figura 13 - Distribuição pluviométrica média local conforme séries históricas de estações convencionais



Fonte: Autor (2019)

Do ponto de vista geológico e geomorfológico, as áreas de pastagem nativa, floresta plantada e campo estão inseridas na Formação Serra da Saudade, advinda do Grupo Bambuí, com idade de formação Neoproterozóica. Essa região é marcada por relevos aplainados, com litotipos predominantes da classe dos siltitos, argilitos e folhelhos cinza esverdeados. Já a floresta nativa está inserida na zona de transição do Grupo Bambuí e apresenta Coberturas

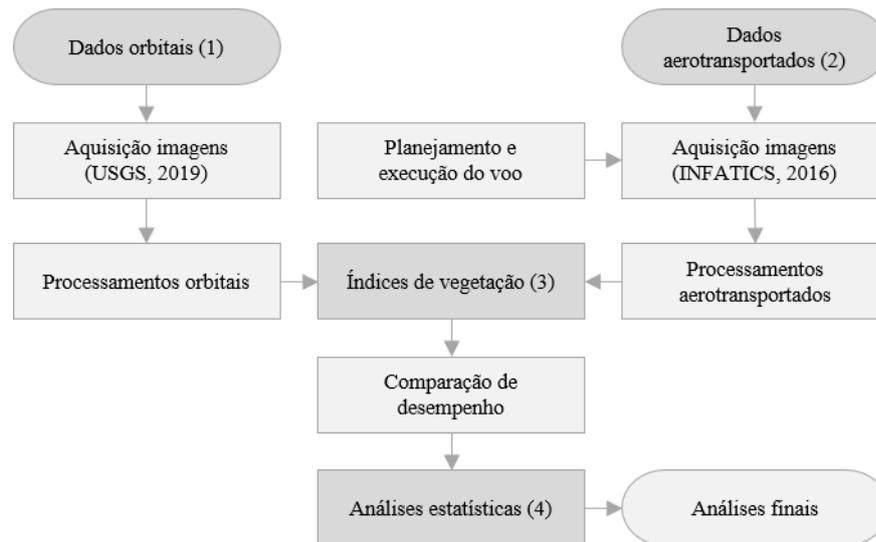
Quaternárias marcadas por sedimentos vulcânicos intemperizados (arenitos e tufos lapillíticos), associados ao Grupo Mata da Corda do período Cretáceo. Por fim, as áreas de pastagem plantada e agricultura estão localizadas em uma região com sobrepostos e depósitos detrito-lateríticos do Neogeno, marcadas por depósitos de areia média, concreções lateríticas e conglomerados (MARQUES et al., 2015; CPRM, 2017).

5.2 MATERIAIS

Para desenvolvimento do estudo, foi utilizado uma base de dados composta por dois conjuntos de imagens, sendo um destes composto por imagens multiespectrais advindas dos satélites S2A e S2B e outro por imagens RGB advindas do quadricóptero DJI, modelo Phantom 4 (DJI, 2016; USGS, 2019). Para os dados advindos dos sensores orbitais, cerca de 73 imagens foram obtidas pelo S2A e S2B referente ao *tile* T23KLV/órbita 38 entre fevereiro de 2018 e janeiro de 2019 (12 meses) e utilizadas no estudo. Já para os dados advindos do sensor aerotransportado, foram adquiridas 5.496 imagens RGB entre fevereiro de 2018 a janeiro de 2019 (12 meses) e convertidas em 72 ortomosaicos. Para essas aquisições, foi utilizado o *software* de planejamento de mapeamento aéreo DroneDeploy a adoção de parâmetros de mapeamento em: altura com 110 metros; sobreposições frontais e laterais com 80% e distância de amostragem de solo (GSD) de 4,7 cm/pixel (INFATICS, 2016). Vale ressaltar que o RPA utilizado está inclusa na classe 3 da Agência Nacional de Aviação Civil (ANAC) e estava devidamente registrada para operações no momento dos mapeamentos (ANAC, 2017).

5.3 MÉTODOS

Como os dados utilizados apresentavam características distintas, dois blocos de processamento foram propostos: um para os dados multiespectrais orbitais e outro para os dados RGB aerotransportados. A Figura 15 apresenta o fluxograma metodológico de processamentos adotado no desenvolvimento deste estudo.

Figura 14 -Fluxograma metodológico

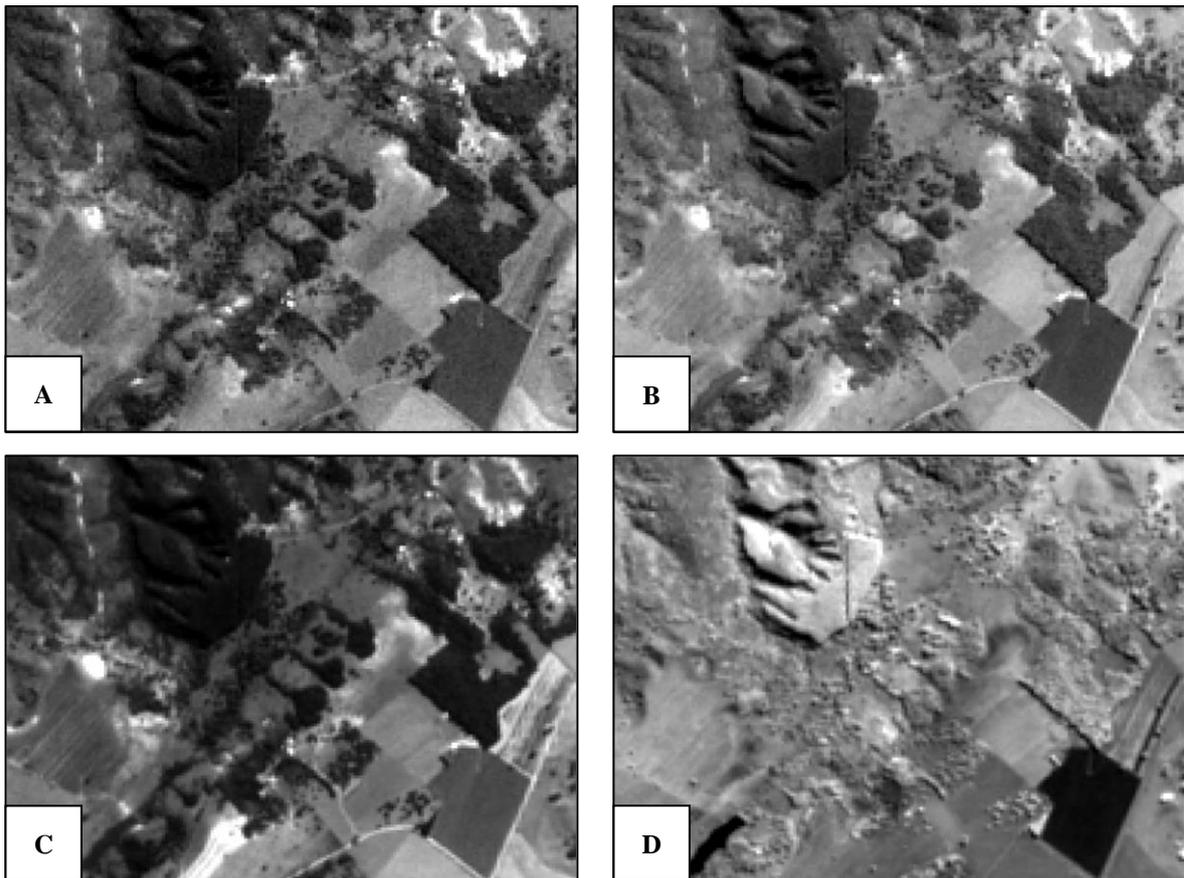
Fonte: Autor (2019)

5.3.1 DADOS ORBITAIS (1)

Apesar das imagens disponibilizadas pelo USGS apresentarem uma série de correções propostas pela ESA, estes dados apresentam nível de processamento correspondente às reflectâncias TOA e precisam ter seus dados convertidos em reflectância da base da atmosfera (BOA) (ESA, 2019a). Rani, Mandla e Singh (2017) afirmam que os procedimentos de transformação e conversão de dados, denominados como correção atmosférica, são importantes pré-requisitos para desenvolvimento de análises da vegetação com dados advindos de sensores orbitais, uma vez que seus objetivos se compreendem em reduzir as interferências de fatores externos a captação.

Dessa forma, os procedimentos de correção atmosférica foram executados com o *software* Sen2Cor v2.5.5, uma adaptação do processador de correção atmosférica ATCOR3, para obtenção dos dados Level-2A (L2A) (RICHTER; SCHLÄPFER, 2016; MÜLLER-WILM, 2018; PADRÓ et al., 2018). Após os procedimentos de correção atmosférica, o conjunto de dados orbitais correspondente às bandas espectrais com resolução espacial de 10 metros (Figura 15), foi preparado com cortes e ajustes no *software* ArcGIS 10.5 para os cálculos dos índices de vegetação no *software* ENVI 5.3 (SOLUTIONS, 2015; ESRI, 2016).

Figura 15 - Imagens Sentinel-2 referentes as bandas espectrais com 10 metros de resolução espacial:
(A) azul, (B) verde, (C) vermelho e (D) NIR



Fonte: Autor (2019)

5.3.2 DADOS AEROTRANSPORTADOS (2)

De posse das imagens obtidas em campo nas respectivas parcelas amostrais com o RPA Phantom 4, um conjunto de processamentos no *software* Agisoft Metashape Professional 1.5 na versão *trial* foi executado para obtenção dos ortomosaicos (TORRADO; CÁCERES; DÍAZ, 2016; LLC, 2018a). Com uma metodologia de processamento adaptada conforme orientações de Córcoles et al. (2013) e Sopchaki et al. (2018), os parâmetros de processamento foram definidos conforme testes, indicações e orientações de desenvolvedores, conforme a Tabela 2.

Quanto aos procedimentos de correção atmosférica, esses foram desconsiderados pelo fato de as interferências serem consideradas insignificantes, graças à baixa altura de mapeamento. Uma observação importante referente deve ser feita quanto ao passo de alinhamento de imagens, uma vez que esse passo apresentou resultados variáveis conforme o tipo de vegetação e tiveram os parâmetros ajustados conforme as necessidades.

Tabela 2 - Metodologia de processamento empregada no Agisoft Metashape Professional 1.5

Ordem	Processo	Parâmetros	
		Gerais	Avançados
1	Align Photos*	Accuracy: High* Generic/Reference preselection: Yes* Reset current alignment: No	Key/Tie point limit: 4.000* Apply masks to: None Adaptative camera model fitting: Yes
2	Reference Ground Points	-	-
3	Align Photos*	Accuracy: High* Generic/Reference preselection: Yes* Reset current alignment: Yes	Key/Tie point limit: 4.000* Apply masks to: None Adaptative camera model fitting: Yes
4	Optimize Alignment	-	Adaptative camera model fitting: Yes
5	Calibrate Colors	Source data: Sparse cloud Calibrate white balance: Yes	-
6	Build Dense Cloud	Quality: High	Depth filtering: Aggressive Reuse depth maps: No Calculate point colors: No
7	Classify Ground Points	From: Any class To: Ground + Low Points	Max angle (°): 15,0 Max distance (m): 5,0 Cell size (m): 100
8	Build Mesh	Surface type: Arbitrary (3D) Source data: Dense cloud Face count: Medium	Interpolation: Enabled (default) Point classes: Ground Calculate vertex colors: No
9	Calibrate Colors	Source data: Model Calibrate white balance: Yes	-
10	Build Texture	Mapping mode: Generic Texture from: All cameras Blending mode: Mosaic Texture size: 4.096 Texture count: 1	Hole filling: Yes Enable ghosting filter: Yes
11	Build Tiled Model	Source data: Dense cloud Pixel size (m): 0 Tile size: 2048	Enable ghosting filter: Yes Reuse depth maps: No
12	Build DEM	Source data: Dense cloud Interpolation: Enabled (default) Point classes: Ground	Resolution (m): 0 Total size (pix): Default
13	Calibrate Colors	Source data: DEM Calibrate white balance: Yes	-
14	Build Orthomosaic	Surface: DEM Blending mode: Mosaic (default) Enable hole filling: Yes Enable back-face culling: No Pixel size (°): Default	Total size (pix): Estimate

Fonte: Autor (2019)

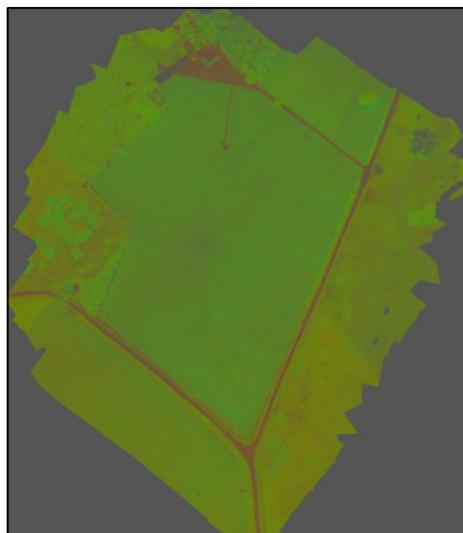
Após a obtenção dos ortomosaicos, autores como Cheng et al. (2001), Saberioon et al. (2014), Torres-Sánchez et al. (2014), Zhou et al. (2017) e Ballesteros et al. (2018) recomendam que seja executada a normalização de seus números digitais (DN) para a redução das distorções causadas pelas luzes e sombras. Tal procedimento foi executado por meio das Equações 5 em todo o conjunto de dados aerotransportados, tendo um exemplo de imagem normalizada demonstrada na Figura 16. Posteriormente aos procedimentos de normalização, todo o conjunto de dados foi preparado com cortes e manipulações extras no *software* ArcGIS 10.5, tendo os índices de vegetação calculados no *software* ENVI 5.3 (SOLUTIONS, 2015; ESRI, 2016).

$$b = \frac{B}{R + G + B}; g = \frac{G}{R + G + B}; r = \frac{R}{R + G + B}; \quad (\text{Equação 5})$$

Em que

- b: valor de DN na faixa espectral do azul normalizado;
- g: valor de DN na faixa na faixa espectral do verde normalizado;
- r: valor de DN na faixa na faixa espectral do vermelho normalizado;
- B: valor de DN na faixa espectral do azul;
- G: valor de DN na faixa na faixa espectral do verde;
- R: valor de DN na faixa na faixa espectral do vermelho.

Figura 16 - Ortomosaico com pixels normalizados



Fonte: Autor (2019)

5.3.3 ÍNDICES DE VEGETAÇÃO (3)

Como o objetivo dessa pesquisa foi avaliar o potencial de aplicação dos índices de vegetação baseados exclusivamente na porção visível do espectro eletromagnético em imagens advindas de sensoriamento remoto orbital e sub-orbital, quatro índices de vegetação foram propostos para verificação dessas potencialidades. A Tabela 3 apresenta um resumo descritivo dos índices utilizados neste estudo, com informações básicas referentes aos seus respectivos nomes, domínio espectral, siglas, equações e referências bibliográficas.

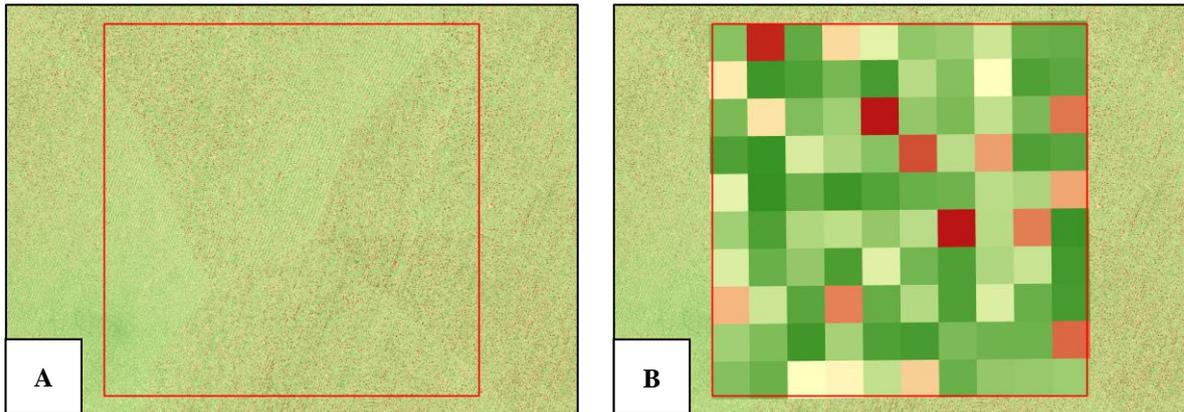
Tabela 3 - Descrição de índices de vegetação utilizados

Nome	Domínio	Sigla	Equação	Referência
<i>Green Leaf Index</i>	VIS	GLI	$\frac{(2 * G - R - B)}{(2 * G + R + B)}$	(LOUHAICHI; BORMAN; JOHNSON, 2001)
<i>Normalized Difference Vegetation Index</i>	VNIR	NDVI	$\frac{(NIR - R)}{(NIR + R)}$	(ROUSE et al., 1974)
<i>Normalized Green-Red Difference Index</i>	VIS	NGRDI	$\frac{(G - R)}{(G + R)}$	(TUCKER, 1979)
<i>Visible Atmospherically Resistant Index</i>	VIS	VARI	$\frac{(G - R)}{(G + R - B)}$	(GITELSON et al., 2002)

Fonte: Autor (2019)

Nota-se que dentre os índices de vegetação utilizados, o NDVI é o único que emprega em sua equação a informação espectral do comprimento de onda do NIR, sendo calculado exclusivamente para os dados orbitais. Apesar deste índice não ser o foco principal das avaliações propostas, sua adoção em meio aos índices orbitais foi considerada importante pelo fato dele ser considerado a métrica de análise da vegetação mais bem sucedida na história do sensoriamento remoto e servir como base de comparação para as demais métricas (CARRÃO et al., 2002; HUETE et al., 2002). Ressalta-se que os índices advindos das imagens aerotransportadas, cuja resolução espacial média foi de aproximadamente 4,53 cm/pix, tiveram seus pixels reamostrados com o método do vizinho mais próximo para uma resolução espacial de 10 metros, com o objetivo de compatibilizar as resoluções espaciais para futuras comparações (Figura 17).

Figura 17 - Reamostragem dos dados aerotransportados de 4,53 cm/pix (A) para 10 m/pix (B)



Fonte: Autor (2019)

5.3.4 ANÁLISES ESTATÍSTICAS (4)

Para o desenvolvimento das análises estatísticas, foram utilizados os valores extraídos de cada um dos pixels contidos nas parcelas amostrais referentes a cada uma das repetições orbitais e aerotransportadas. Como as parcelas amostrais tiveram área total de 10.000 m², essas dimensões foram equivalentes a exatamente 100 pixels com resolução espacial de 10 metros. Dessa forma, todos os valores individuais dos pixels foram utilizados para as análises estatísticas, sendo empregadas no *software* RStudio Versão 1.1.456 (TEAM, 2015) de maneira independente em três blocos: com dados orbitais/aerotransportados (1), com dados orbitais (2) e com os dados aerotransportados (3).

Quanto aos testes e análises estatísticas em específico, o teste de normalidade de Shapiro-Wilk foi o primeiro a ser utilizado para análise do comportamento das distribuições de probabilidade, uma vez que apresenta um melhor desempenho que outros testes existentes (SHAPIRO; WILK, 1965; TORMAN; COSTER; RIBOLDI, 2012). Como os dados no geral não apresentaram pressupostos de normalidade a uma significância de 5% em algum dos casos, o teste não-paramétrico de correlação de postos de Spearman foi utilizado para avaliação da intensidade de correlação entre as variáveis analisadas (SPEARMAN, 1904).

Como um dos objetivos do estudo foi de analisar as relações existentes entre as variáveis, os modelos lineares generalizados (GLM) foram utilizados a fim de se obter ainda mais conclusões acerca dos comportamentos das médias variáveis. Dessa forma, uma análise de desvios residuais foi executada para verificar os menores erros, uma vez que houve a transformação dos dados ao quadrado, ao logaritmo e à normalização. Por fim, uma análise de variância ANOVA, juntamente ao teste de hipótese “F”, foi utilizada para avaliar as

interações entre as médias das variáveis analisadas, com auxílio das significâncias e contrastes para evidenciar as diferenças, semelhanças e significâncias entre os tratamentos (CRAWLEY, 2007; CRISTALDO et al., 2016).

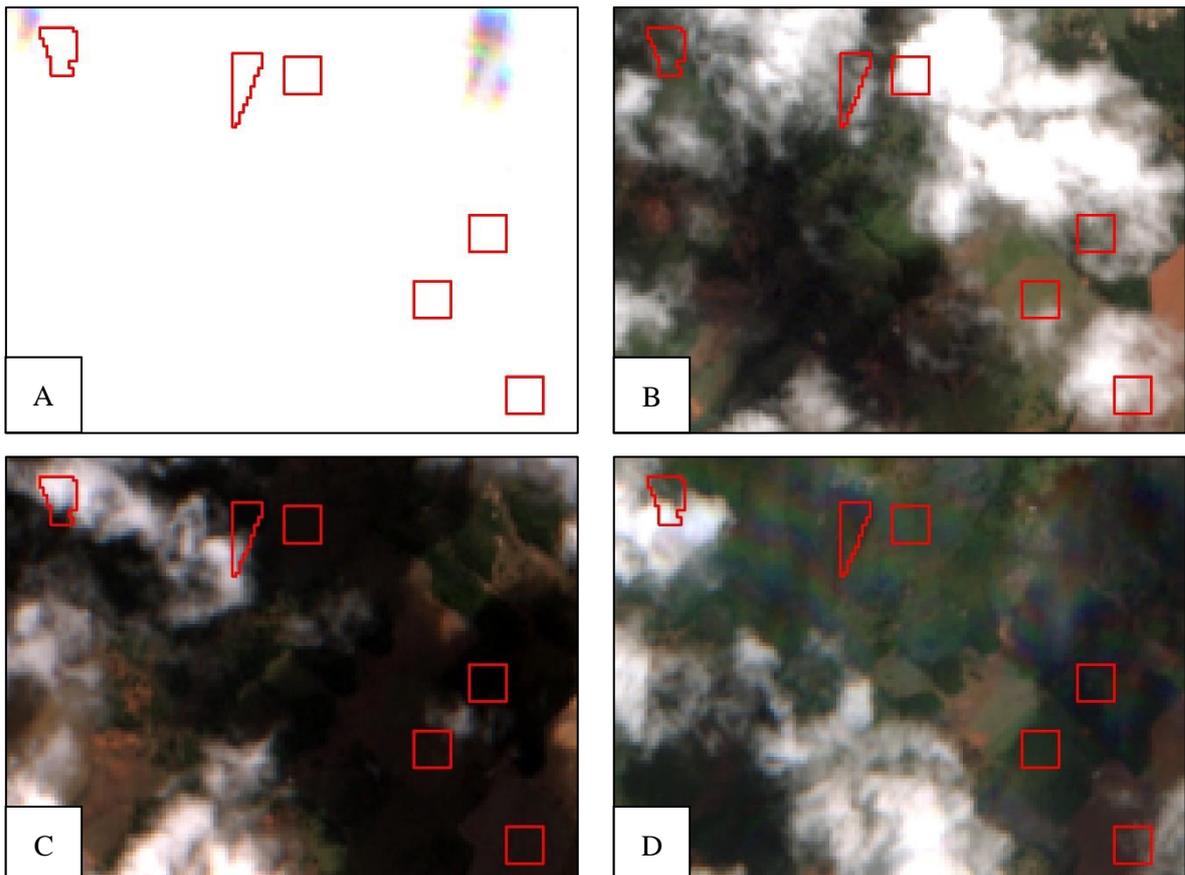
6 RESULTADOS

Para um melhor entendimento dos resultados obtidos com o desenvolvimento desta pesquisa, eles foram divididos em diferentes tópicos e discutidos individualmente a seguir.

6.1 DADOS UTILIZADOS

Com um total de 73 imagens orbitais e 72 imagens aerotransportadas, ambos os conjuntos de dados utilizados neste estudo foram submetidos aos procedimentos metodológicos propostos para cada um deles. Para os dados orbitais, cerca de 38 (52,05%) imagens apresentaram interferências atmosféricas significativas (Figura 18) e foram descartadas de qualquer tipo de análise subsequente. Dessa forma, restaram apenas 35 (47,95%) com condições de serem utilizadas no estudo, sendo 25 (34,25%) classificadas como totalmente aptas e 10 (13,70%) como parcialmente aptas.

Figura 18 - Interferências atmosféricas identificadas nas imagens orbitais: (A) nuvens; (B) nuvens parciais; (C) sombras e (D) arco-íris



Fonte: Autor (2019)

Quanto às imagens advindas do sensor aerotransportado, não foi possível constatar quaisquer limitações advindas de fatores atmosféricos nas 72 (100,00%) imagens. Porém, suas captações se mostraram totalmente dependentes de condições climáticas favoráveis, uma vez que os regimes pluviométricos adversos apresentaram a capacidade de prejudicar diretamente no planejamento e execução dos mapeamentos.

O fato de a grande indisponibilidade de dados orbitais ocorrer em mais este estudo apenas reafirma a existência de problemas inerentes à temporalidade e interferências atmosféricas em imagens orbitais, fator esse que eventualmente pode inviabilizar o seu uso em aplicações de monitoramento. Em casos como esse, onde observa-se uma clara interferência na disponibilidade de dados, a utilização de plataformas alternativas para captação de dados como os RPAs se mostra cada vez mais viável, por seus resultados apresentarem menores interferências a esse tipo de limitação.

6.2 ESTATÍSTICA DESCRITIVA

Trentin, Saldanha e Kuplich (2013) afirmam que as fitofisionomias com estrutura e composição vegetal totalmente diferentes apresentam características e composições espectrais totalmente distintas quando analisadas via sensoriamento remoto. E como esse estudo buscou compreender as variações espectrais existentes entre as diferentes fitofisionomias do Cerrado por meio dos índices espectrais de vegetação, a Tabela 4 apresenta um resumo descritivo com os resultados médios obtidos em cada uma das variáveis.

Ao observar os resultados expressos nessa tabela, é possível notar que para os dados orbitais ocorre uma predominância de menores valores médios na parcela de agricultura e maiores valores médios na parcela de floresta plantada em todos os índices. Observa-se também a existência de um determinado padrão de comportamento nas variações do GLI, NGRDI e VARI quando comparados ao NDVI. Contudo, menores amplitudes são identificadas no GLI, NDVI e NGRDI, enquanto no VARI essas variações se apresentam mais elevadas.

Tabela 4 - Resumo descritivo dos valores médios dos índices de vegetação

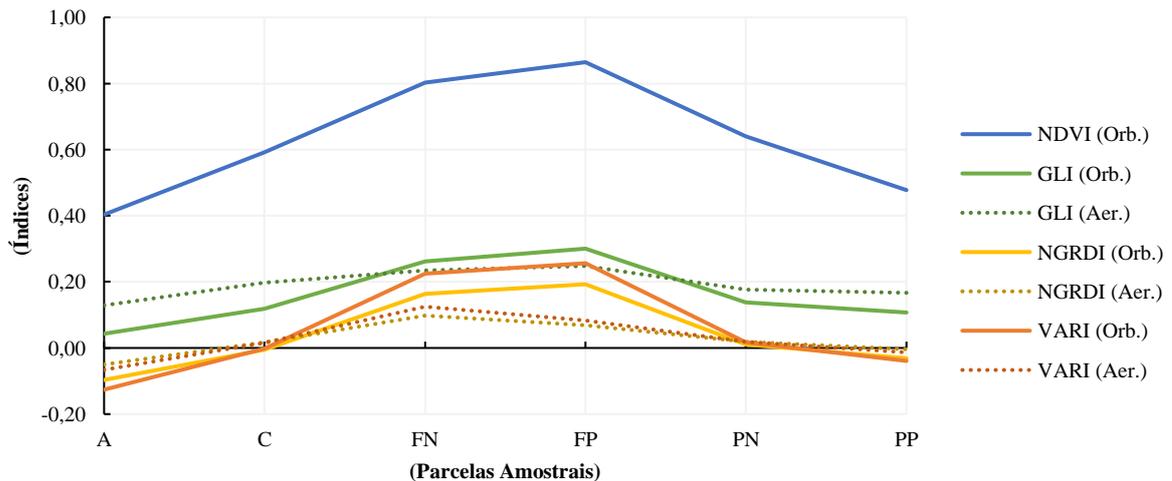
Parcelas	Orbitais																			
	GLI					NDVI					NGRDI					VARI				
	Min.	Med.	Max.	DP.	Amp.	Min.	Med.	Max.	DP.	Amp.	Min.	Med.	Max.	DP.	Amp.	Min.	Med.	Max.	DP.	Amp.
A	0,017	0,043	0,069	0,010	0,052	0,375	0,404	0,433	0,012	0,058	-0,126	-0,097	-0,069	0,011	0,057	-0,165	-0,126	-0,088	0,015	0,077
C	0,086	0,118	0,150	0,013	0,064	0,560	0,591	0,616	0,012	0,057	-0,042	-0,005	0,030	0,015	0,072	-0,053	-0,002	0,048	0,021	0,101
FN	0,176	0,262	0,355	0,034	0,179	0,754	0,802	0,849	0,019	0,095	0,072	0,163	0,268	0,038	0,197	0,103	0,225	0,365	0,051	0,261
FP	0,236	0,301	0,364	0,026	0,128	0,839	0,864	0,886	0,010	0,047	0,121	0,193	0,263	0,028	0,142	0,162	0,256	0,348	0,038	0,185
PN	0,055	0,137	0,214	0,031	0,158	0,534	0,640	0,717	0,034	0,183	-0,083	0,010	0,100	0,036	0,183	-0,110	0,018	0,138	0,049	0,249
PP	0,074	0,107	0,140	0,013	0,066	0,439	0,477	0,515	0,016	0,076	-0,068	-0,031	0,007	0,015	0,075	-0,087	-0,039	0,012	0,020	0,100
Média	0,107	0,161	0,215	0,021	0,108	0,583	0,630	0,669	0,017	0,086	-0,021	0,039	0,100	0,024	0,121	-0,025	0,055	0,137	0,032	0,162
Parcelas	Aerotransportados																			
	GLI					NDVI					NGRDI					VARI				
	Min.	Med.	Max.	DP.	Amp.	Min.	Med.	Max.	DP.	Amp.	Min.	Med.	Max.	DP.	Amp.	Min.	Med.	Max.	DP.	Amp.
A	-0,053	0,129	0,352	0,063	0,405	-	-	-	-	-	-0,254	-0,050	0,183	0,060	0,436	-0,280	-0,066	0,179	0,063	0,459
C	0,070	0,197	0,341	0,043	0,271	-	-	-	-	-	-0,077	0,017	0,094	0,027	0,171	-0,097	0,015	0,101	0,032	0,198
FN	0,062	0,234	0,587	0,093	0,525	-	-	-	-	-	-0,023	0,098	0,393	0,066	0,416	-0,028	0,125	0,447	0,076	0,475
FP	0,014	0,248	0,511	0,095	0,497	-	-	-	-	-	-0,129	0,069	0,296	0,071	0,425	-0,177	0,083	0,360	0,088	0,537
PN	0,012	0,176	0,423	0,082	0,411	-	-	-	-	-	-0,111	0,019	0,185	0,048	0,296	-0,139	0,019	0,204	0,057	0,344
PP	0,070	0,167	0,299	0,043	0,230	-	-	-	-	-	-0,085	-0,004	0,065	0,024	0,149	-0,111	-0,013	0,067	0,029	0,177
Média	0,029	0,192	0,419	0,070	0,390	-	-	-	-	-	-0,113	0,025	0,203	0,049	0,316	-0,139	0,027	0,226	0,058	0,365

Fonte: Autor (2019)

Já para os dados aerotransportados, os comportamentos dos índices de vegetação nas diferentes parcelas amostrais são definidos como semelhantes aos obtidos nos dados orbitais. É possível observar que para o GLI ocorre um padrão de comportamento mínimo, médio e máximo idêntico aos observados nos dados orbitais. Entretanto, para o NGRDI e VARI, essa igualdade de comportamento não é visualizada, uma vez que os menores valores médios se fazem presentes na parcela de agricultura e os maiores valores na parcela de floresta nativa. Quanto aos comportamentos que GLI, NGRDI e VARI aerotransportados apresentam quando comparados com o NDVI, é possível notar uma similaridade entre eles com menores amplitudes de variação no GLI e NGRDI e maiores variações no VARI.

A título de ilustração, a Figura 19 apresenta de forma gráfica os valores médios dos índices orbitais e aerotransportados, sendo possível reafirmar que mesmo em dados com características distintas ocorre um padrão de comportamento semelhante em todas as parcelas. É possível notar também que em ambos os casos o GLI se mostra um índice mais sensível e com maiores amplitudes de resultados médios que o NGRDI e o VARI. Entretanto, não necessariamente essa característica o define como o que apresenta as maiores similaridades ao NDVI.

Figura 19 - Distribuição de valores médios para os índices nas diferentes parcelas amostrais



Fonte: Autor (2019)

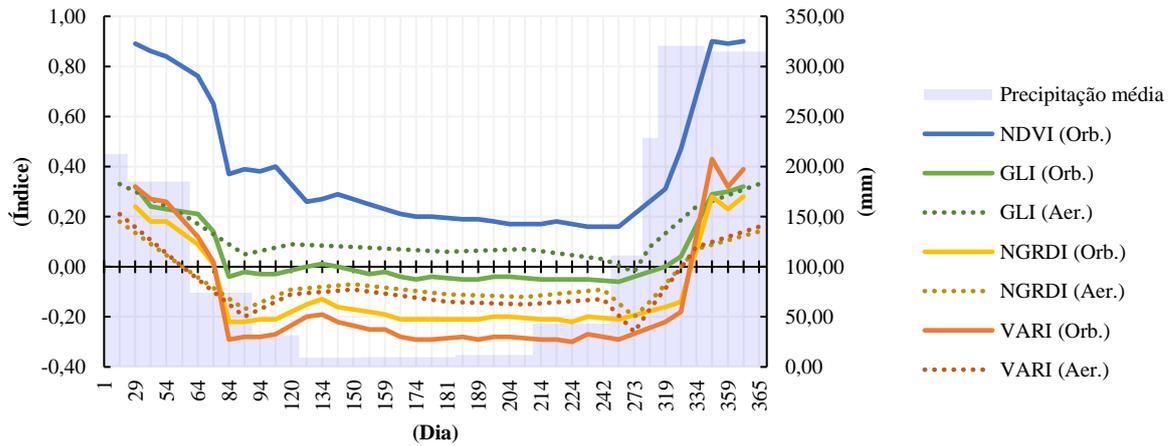
Outra observação a ser levada em conta ao analisar os resultados se dá pela predominância de maiores resultados dos índices nas parcelas referentes às formações florestais, seguido pelas formações campestres e por fim pela área agrícola. Esse comportamento com altos valores presentes nas formações florestais pode ser explicado pelo fato de que as vegetações com extrato arbóreo apresentam uma maior estabilidade

fotossintética e hídrica durante todo o período analisado, o que conseqüentemente acarreta em maiores reflectâncias médias durante o período de monitoramento. Para as vegetações com extrato herbáceo-arbustivo, cujos comportamentos temporais são altamente susceptíveis a variações ocasionadas pela alternância dos regimes hídricos, uma estabilidade fotossintética e hídrica não se faz presente em suas características e menores reflectâncias médias são observadas durante todo o período analisado. Já na parcela referente à agricultura, as respostas espectrais se mostraram altamente influenciadas pelos ciclos hidrológicos e pelos períodos de plantio e colheita da cultura, tendo essas interferências influenciado significativamente o comportamento temporal dos índices de vegetação em escala temporal (FERREIRA et al., 2006; NUNES; SOUZA-FILHO; FERREIRA, 2012).

6.3 SÉRIES TEMPORAIS

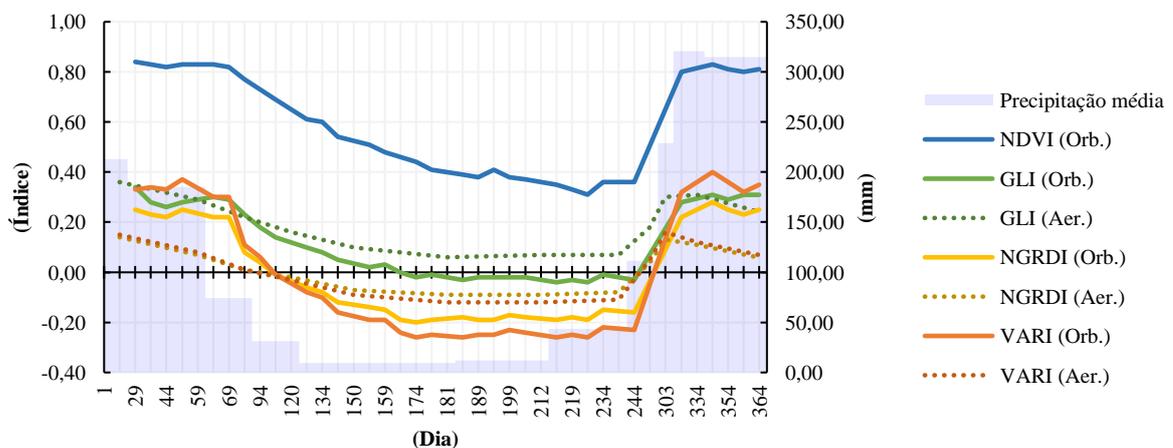
Para um melhor entendimento dos comportamentos temporais que os índices de vegetação assumiram em cada uma das repetições, da Figura 20 até a 25 são apresentadas as médias dos índices obtidos entre 01/02/2018 (dia 1) até 31/01/2019 (dia 365). No geral, pode-se dizer que para os dados advindos dos sensores orbitais, os comportamentos espectro-temporais identificados neste estudo foram semelhantes aos obtidos por Ferreira et al. (2006) em sua pesquisa. Já para os dados advindos do sensor aerotransportado, os mesmos padrões observados nos dados orbitais foram identificados no conjunto de dados aerotransportados, com diferenças básicas principalmente na amplitude e na magnitude das variações.

Especificamente na Figura 20 são apresentados os perfis temporais médios dos índices de vegetação correspondentes à parcela de agricultura. Como nessa parcela existe a predominância de apenas uma espécie vegetal com ciclo anual, as variações dos resultados foram mais evidentes nos períodos de desenvolvimento/interrupção do cultivo e com alterações abruptas entre o início e o término dos períodos chuvosos. Verifica-se também que nesta parcela, cuja vegetação se assemelha em características fisiológicas às parcelas com extrato herbáceo-arbustivo, ocorre um mesmo padrão de comportamento, semelhante entre as parcelas amostrais com fitofisionomias parecidas (FERREIRA; HUETE, 2004; FERREIRA et al., 2006). Quanto às similaridades entre os índices orbitais e aerotransportados, ambos os dados seguiram os mesmos padrões de tendências e sazonalidades, com quedas de valores nos períodos secos e alta nos períodos chuvosos.

Figura 20 - Série temporal referente a parcela de agricultura

Fonte: Autor (2019)

Já na Figura 21, são apresentados os perfis temporais médios correspondentes aos índices de vegetação na parcela de campo. É possível observar que nesse caso, assim como ocorre na agricultura, existem determinados padrões de comportamento advindos principalmente das variações causadas pela perda de biomassa verde e pelas sazonalidades pluviométricas. Entretanto, essas variações apresentam caráter distinto da agricultura, uma vez que não apresentam intervenções de caráter antrópico na estrutura e composição da vegetação desta parcela. Quanto às semelhanças que as séries temporais dos índices orbitais e aerotransportados apresentam, ambos seguiram os mesmos padrões de comportamento de tendência e sazonalidade, com quedas de valores em períodos secos e alta de valores em períodos chuvosos.

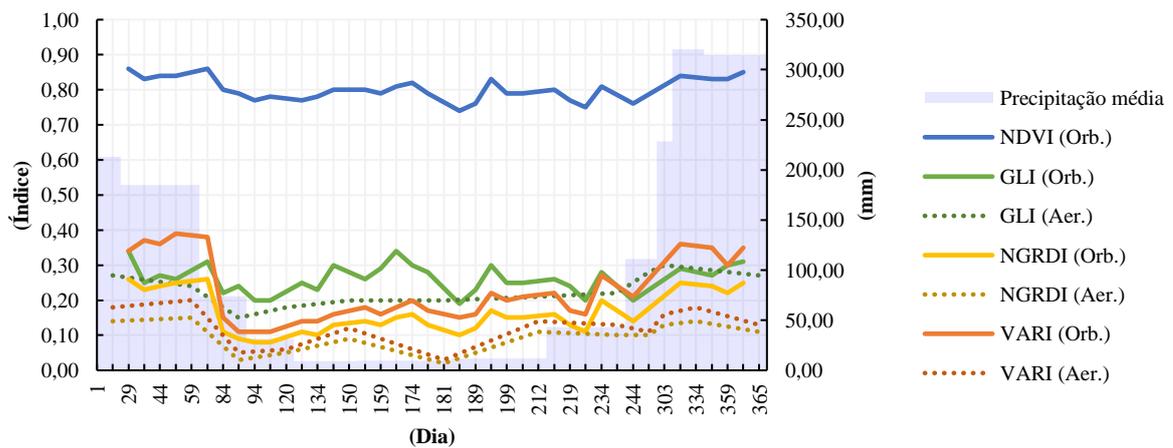
Figura 21 - Série temporal referente a parcela de campo

Fonte: Autor (2019)

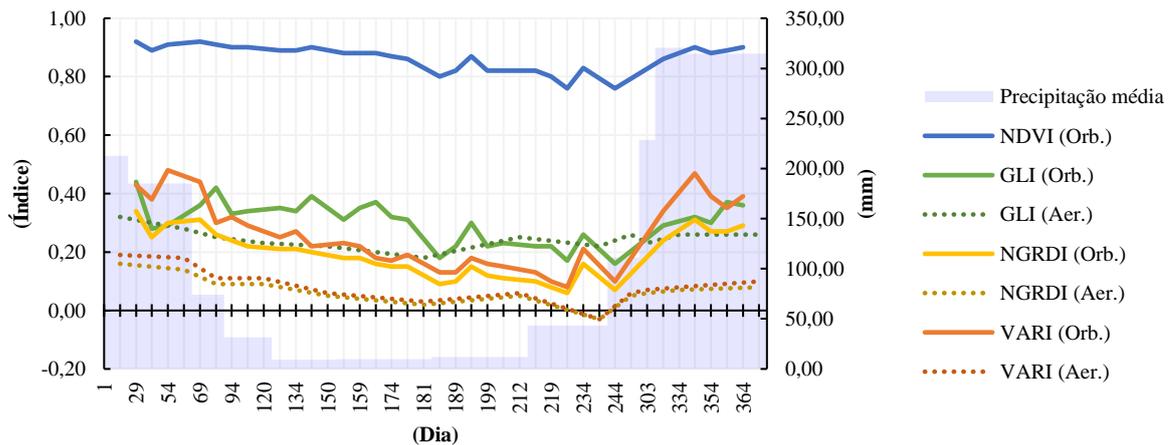
Quanto às Figuras 22 e 23, são apresentados os perfis temporais médios dos índices de vegetação referentes à floresta nativa e floresta plantada, respectivamente. Como já era esperado para essas parcelas, menores variações foram observadas durante o período analisado, uma vez que essas formações apresentam maiores estabilidades fotossintéticas, elevadas disponibilidades hídricas e maiores reflectâncias médias durante todo o período analisado (FERREIRA et al., 2006; NUNES; SOUZA-FILHO; FERREIRA, 2012). Em concordância ao que é mostrado em outros trabalhos, observa-se que nas fitofisionomias cujo extrato vegetal apresentam características arbóreas, ocorre um padrão de comportamento nas respostas espectro-temporais, com alterações mais relacionadas aos parâmetros superficiais, estruturais e funcionais do que com variações climáticas (COHEN et al., 2003; WANG et al., 2004).

Para os comportamentos que os índices de vegetação assumem nos dados orbitais e aerotransportados, é possível observar um mesmo padrão para ambos os casos. Entretanto, para a floresta nativa, apesar de uma alteração abrupta ocorrer no início da série, uma dinâmica de alterações se mostra mais lenta e menos sensível que na área de floresta plantada, visto que essa vegetação se constitui em uma cobertura mais robusta e resistente a qualquer tipo de variações (CARVALHO-JÚNIOR et al., 2010).

Figura 22 - Série temporal referente a parcela de floresta nativa

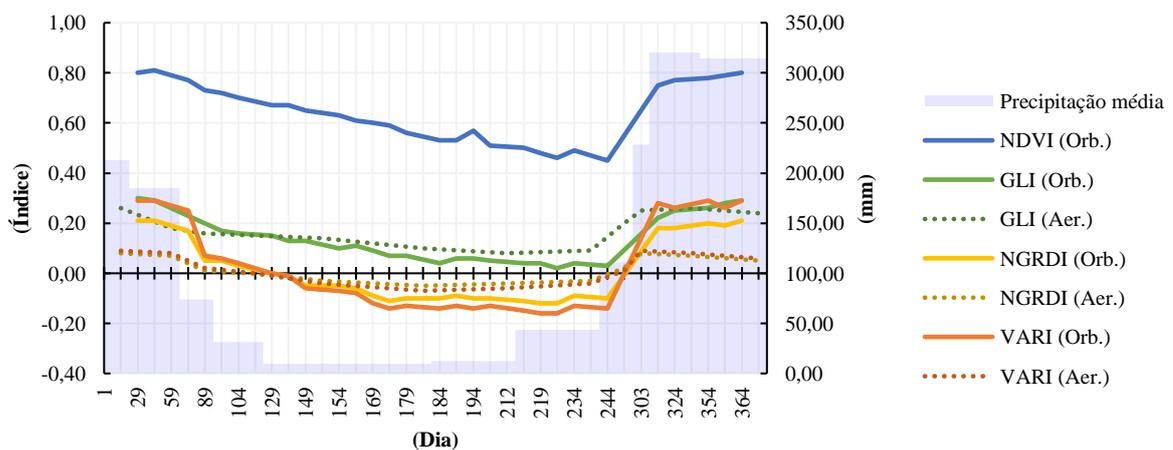


Fonte: Autor (2019)

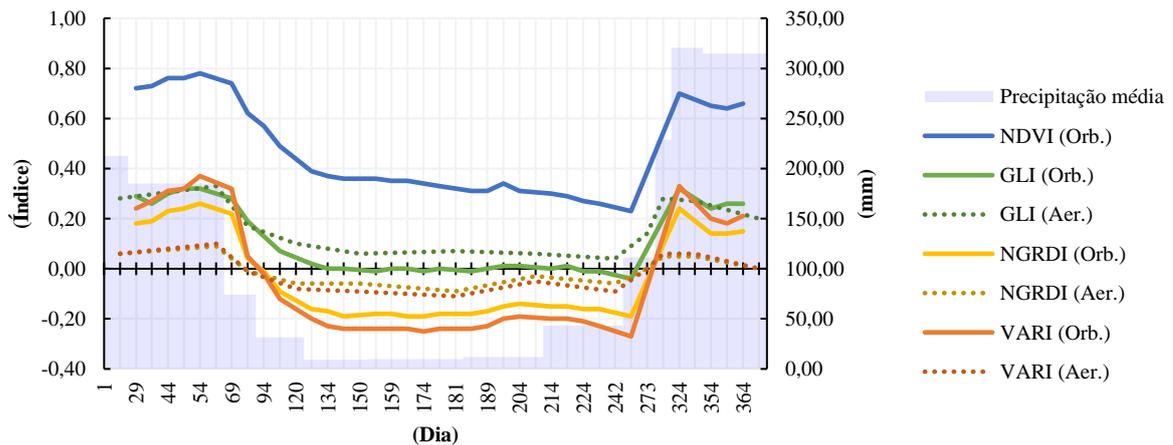
Figura 23 - Série temporal referente a parcela de floresta plantada

Fonte: Autor (2019)

Nas Figuras 24 e 25 são apresentados os perfis temporais médios correspondentes aos índices de vegetação para a pastagem nativa e a pastagem plantada, respectivamente. De forma semelhante aos comportamentos apresentados pelas parcelas de agricultura e campo, as parcelas de pastagem nativa e de pastagem plantada apresentam comportamentos que se mostram totalmente influenciados pela perda de biomassa e pelos períodos de estiagem pluviométrica. Entretanto, as variações identificadas nessas parcelas amostrais apresentam respostas mais estáveis e menos sensíveis que na agricultura e no campo, com comportamentos extremamente semelhantes entre si e maior resistência da parcela nativa. Quanto às semelhanças entre os índices orbitais e aerotransportados, ambos também seguiram os mesmos padrões de comportamento, com quedas em períodos secos e alta de valores em períodos chuvosos.

Figura 24 - Série temporal referente a parcela de pastagem nativa

Fonte: Autor (2019)

Figura 25 - Série temporal referente a parcela de pastagem plantada

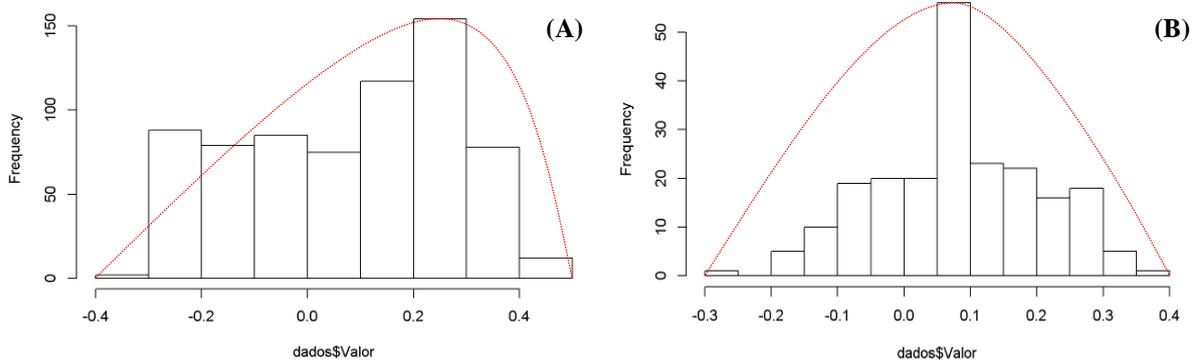
Fonte: Autor (2019)

6.4 ANÁLISES COMPARATIVAS

Após um conjunto de avaliações descritivas ser empregada nos índices e nas séries temporais correspondentes a cada uma das parcelas amostrais, algumas análises de correlação entre variáveis foram propostas para avaliar o grau das similaridades entre os índices GLI, NGRDI e VARI (variável dependente) e o NDVI (variável independente). O teste de Shapiro-Wilk foi o teste escolhido para avaliar as condições de normalidade que os conjuntos de dados apresentam, permitindo, assim, uma melhor definição do teste estatístico para essa situação em específico (SHAPIRO; WILK, 1965).

A Figura 26 apresenta os histogramas referentes aos testes de normalidade a um nível de significância estatística de 5% para os conjuntos de dados orbitais e aerotransportados. Como os resultados dos testes de normalidade apresentaram comportamentos distintos, os dados aerotransportados indicaram pressupostos de normalidade ($p\text{-value} = 0.124$) e os dados orbitais não seguiram esse mesmo comportamento, rejeitando a hipótese de normalidade ($p\text{-value} < 2.2e^{-16}$). Dessa forma, o teste não-paramétrico de correlação de postos de Spearman foi proposto para avaliar as correlações existentes entre as variáveis, por ser o teste mais indicado para esse tipo de situação (SPEARMAN, 1904).

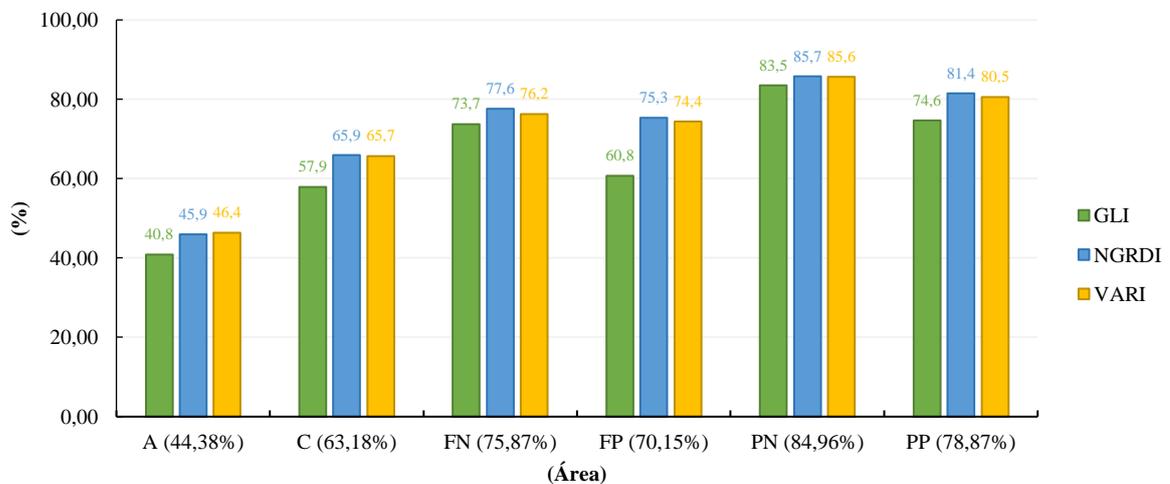
Figura 26 - Histogramas resultantes do teste de Shapiro-Wilk para dados orbitais (A) e dados aerotransportados (B)



Fonte: Autor (2019)

A Figura 27 exhibe as correlações médias existentes para os índices de vegetação advindos dos dados orbitais ao NDVI. Nesse caso em específico, foi observada uma correlação média geral de 69,57% para todos os índices e parcelas, sendo considerada uma correlação moderada entre variáveis, principalmente pelo NGRDI, seguido pelo VARI e GLI (CALLEGARI-JACQUES, 2003). Os valores médios de correlação por índices individuais estiveram em 71,98% para o NGRDI, 71,49% para o VARI e 65,23% para GLI, enquanto a média por área amostral individual foi de 84,96% para a pastagem nativa, 78,87% para a pastagem plantada, 75,87% para a floresta nativa, 70,15% para a floresta plantada, 63,18% para campo e 44,38% para agricultura.

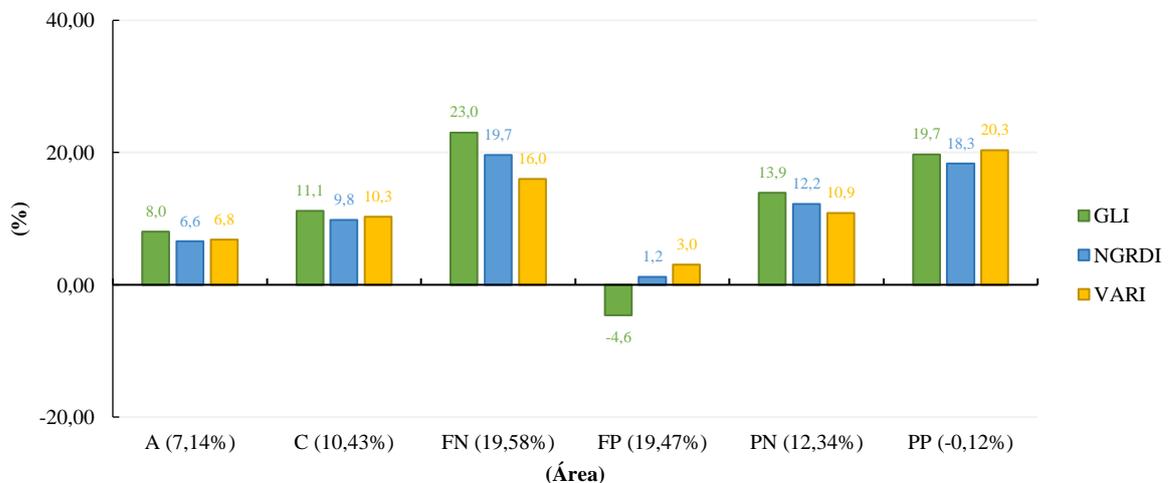
Figura 27 - Correlações entre os índices do visível orbital (dependente) com o NDVI (independente)



Fonte: Autor (2019)

Já a Figura 28 exibe as correlações médias existentes entre os índices de vegetação advindos dos dados aerotransportados e o NDVI. Nesse caso foi observado uma correlação média geral de 11,47% para todos os índices e parcelas, sendo considerada uma correlação fraca entre variáveis, principalmente pelo VARI, seguido pelo NGRDI e GLI (CALLEGARI-JACQUES, 2003). Para as médias de correlação por índice individual, estes estiveram em 11,87% para GLI, 11,31% para o NGRDI e 11,23% para o VARI, com média por área amostral individual de 19,58% para a floresta nativa, 19,47% para a pastagem plantada, 12,34% para a pastagem nativa, 10,43% para o campo, 7,14% para a agricultura e -0,12% para floresta plantada.

Figura 28 - Correlações entre os índices do visível aerotransportados (dependente) com o NDVI (independente)



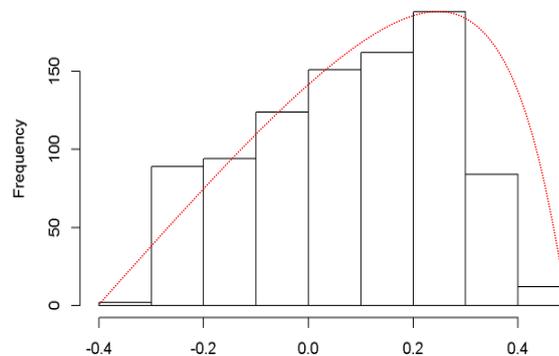
Fonte: Autor (2019)

Quanto aos resultados de comparação entre variáveis, nota-se que não é possível observar um padrão de comportamento para as correlações existentes em ambos os conjuntos de dados, uma vez que as correlações referentes aos dados orbitais foram moderadas, com resultados positivos, enquanto as correlações para os dados aerotransportados foram designadas como baixas de resultados negativos. Esse comportamento de baixíssima correlação entre os índices advindos dos dados aerotransportados com os dados orbitais pode ser explicado por inúmeros fatores distintos. No entanto, para conclusões mais concretas, uma análise sob perspectivas e objetivos diferentes aos propostos por este estudo devem ser feitas para uma melhor caracterização e entendimento dessas variações.

6.5 ANÁLISES DE VARIÂNCIA

Para que fosse possível realizar afirmações mais precisas sobre os comportamentos das médias dos índices de vegetação, uma análise de variância ANOVA, juntamente a um teste de hipótese “F”, foi proposta para melhor caracterizar cada um dos conjuntos de dados analisados. Como os testes de normalidades foram executados nos dados orbitais e aerotransportados de maneira individual, o mesmo teste foi aplicado nos dados orbitais/aerotransportados para melhor caracterização e conhecimento das características dos dados condensados. A Figura 29 apresenta o histograma referente ao teste de normalidade, realizado a um nível de significância estatística de 5% para os dados orbitais/aerotransportados, cujo resultado indica que este agrupamento também não apresenta pressupostos de normalidade ($p\text{-value} < 4.629e^{-13}$).

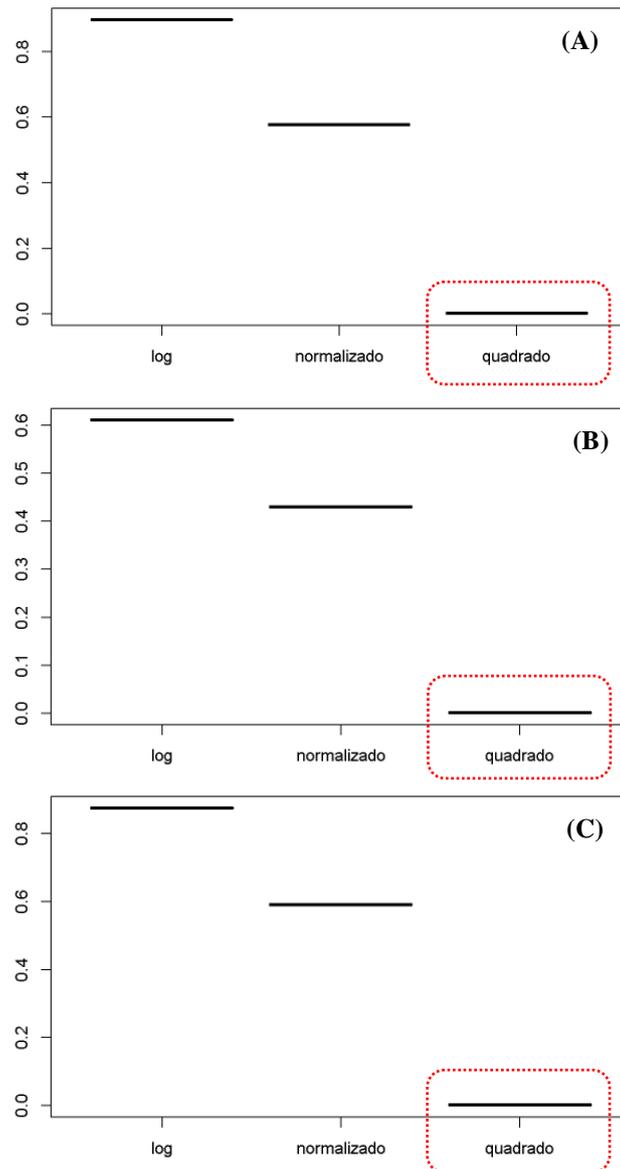
Figura 29 - Histograma resultante do teste de Shapiro-Wilk para os dados orbitais/aerotransportados



Fonte: Autor (2019)

Após as análises estatísticas descritivas básicas serem feitas sobre os conjuntos de dados utilizados, todos os dados foram elevados ao quadrado, logaritimizadas e normalizadas para uma verificação de menores erros residuais, buscando melhor ajustamento ao modelo GLM, uma vez que esta técnica estatística se consolida com alternativa viável, por não exigir pressupostos de normalidade, independência e homocedasticidade. Como é possível observar na Figura 30, as transformações ao quadrado apresentaram os menores erros residuais em todos os casos, sendo essa transformação designada como a melhor para o ajustamento dos dados ao modelo.

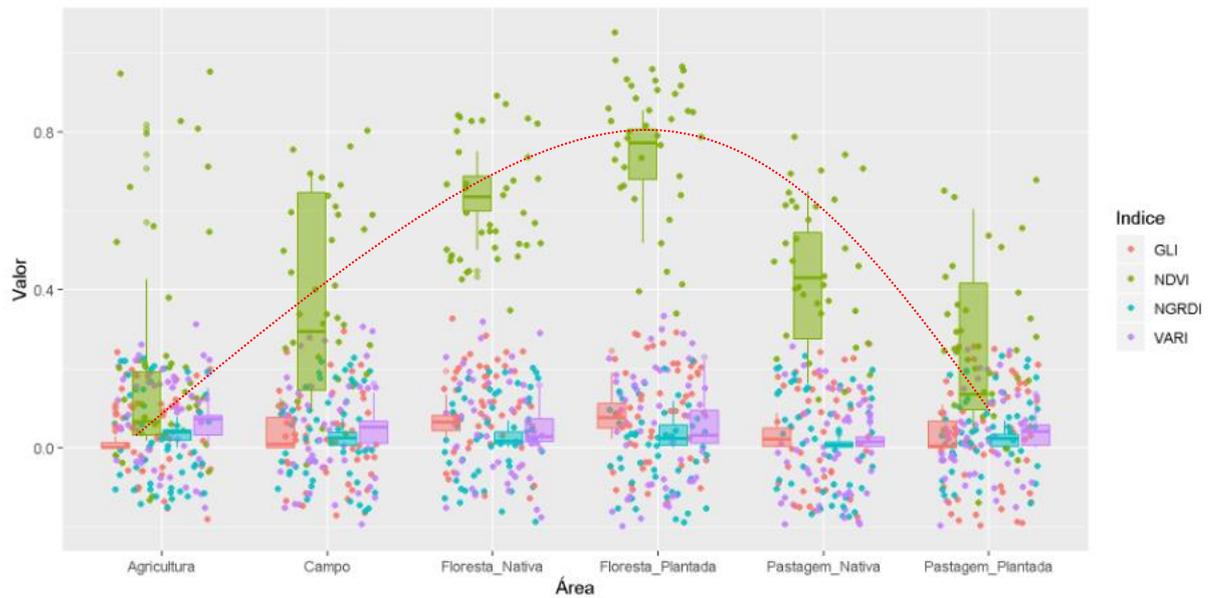
Figura 30 - Avaliação de erros residuais para dados orbitais (A), aerotransportados (B) e orbitais/aerotransportados (C)



Fonte: Autor (2019)

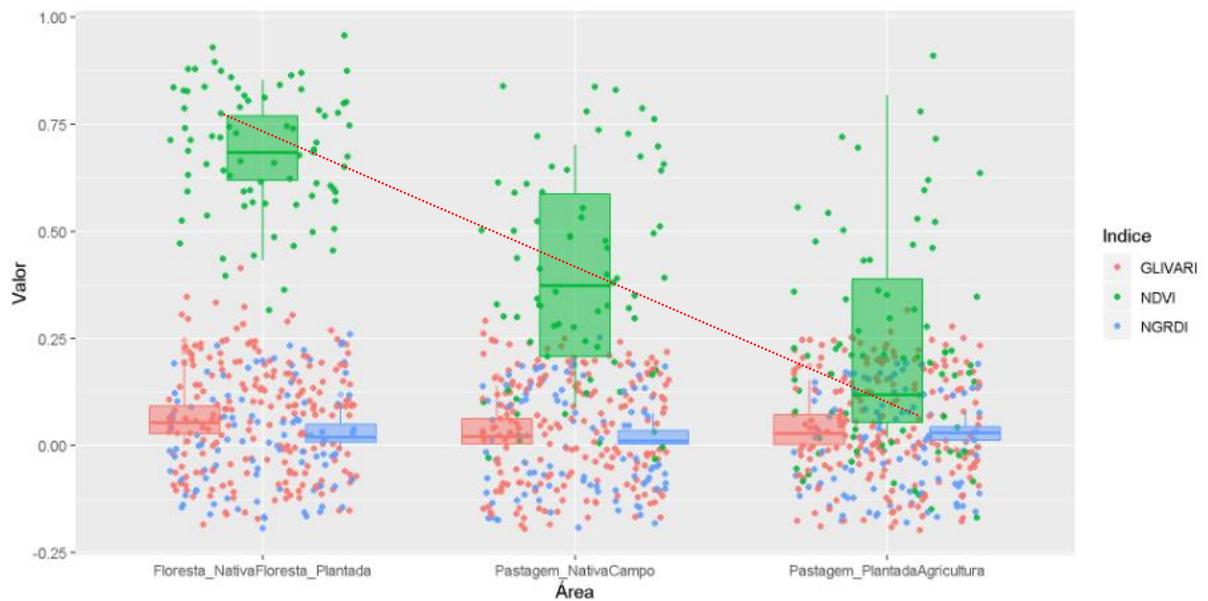
Como o NDVI foi um índice adotado neste estudo apenas como base comparativa para os demais resultados, ele foi desconsiderado das análises de variância por apresentar um comportamento altamente influenciável nos modelos comparativos. Esse comportamento de alta influência pode ser observado nas Figuras 31 e 32, onde observa-se que os seus resultados foram completamente distintos entre todas as variáveis analisadas, seja para o método de captura ($p\text{-value} = 0.008$), quanto para índices de vegetação ($p\text{-value} < 2.2e^{-16}$) ou parcela amostral ($p\text{-value} < 2.2e^{-16}$).

Figura 31 - Análise de variância dos índices de vegetação orbitais/aertransportados ajustado ao modelo GLM com o NDVI



Fonte: Autor (2019)

Figura 32 - Análise de significância de contrastes dos índices de vegetação orbitais/aertransportados com dados agrupados por índices e parcelas com o NDVI



Fonte: Autor (2019)

Ao empregar a análise de variância juntamente ao teste de hipótese nos dados orbitais/aerotransportados, foi possível identificar que os métodos de captura de informações orbital e aerotransportado apresentaram diferenças significativas ($p\text{-value} < 2.2e^{-16}$) entre si. Sendo assim, para que não houvesse interferência nas análises dos índices de vegetação e nas parcelas amostrais de ambos os conjuntos de dados, as análises subsequentes foram realizadas de forma individual, conforme método de captura, para um melhor conhecimento sobre as individualidades e características dos dados analisados.

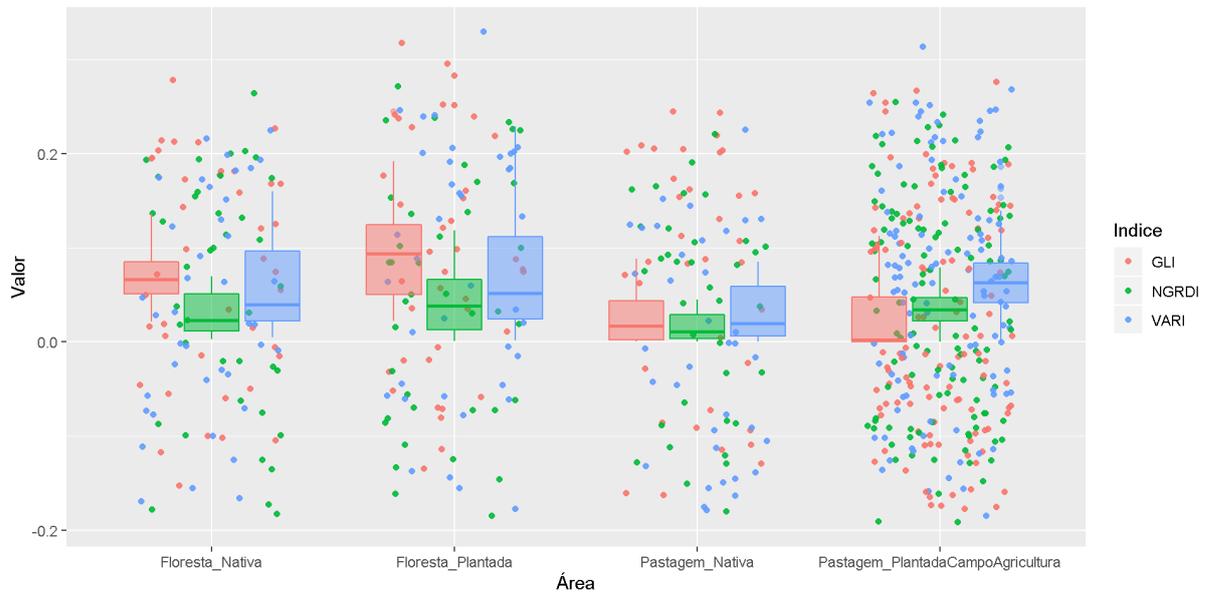
Quanto aos dados orbitais, a análise de variância e o teste de hipótese indicaram que existe uma diferença significativa entre as parcelas amostrais ($p\text{-value} < 2.2e^{-16}$) e os índices de vegetação ($p\text{-value} < 2.5e^{-14}$), a um nível de significância de 5% (Figura 33). Para as avaliações de contrastes (Figura 34), foi possível identificar um comportamento distinto para todos os índices de vegetação, com média por nível de fator de 0,032 para NGRDI, 0,044 para GLI e 0,060 para VARI. Já para as parcelas amostrais de agricultura, campo e pastagem plantada, essas apresentaram comportamentos semelhantes entre si, com média por nível de fator de 0,041, enquanto para a floresta nativa, pastagem nativa e pastagem plantada apresentaram comportamentos distintos das demais parcelas, com média por níveis de fator de 0,024, 0,053 e 0,071, respectivamente.

Figura 33 - Análise de variância dos índices de vegetação ajustados ao modelo GLM para os dados orbitais



Fonte: Autor (2019)

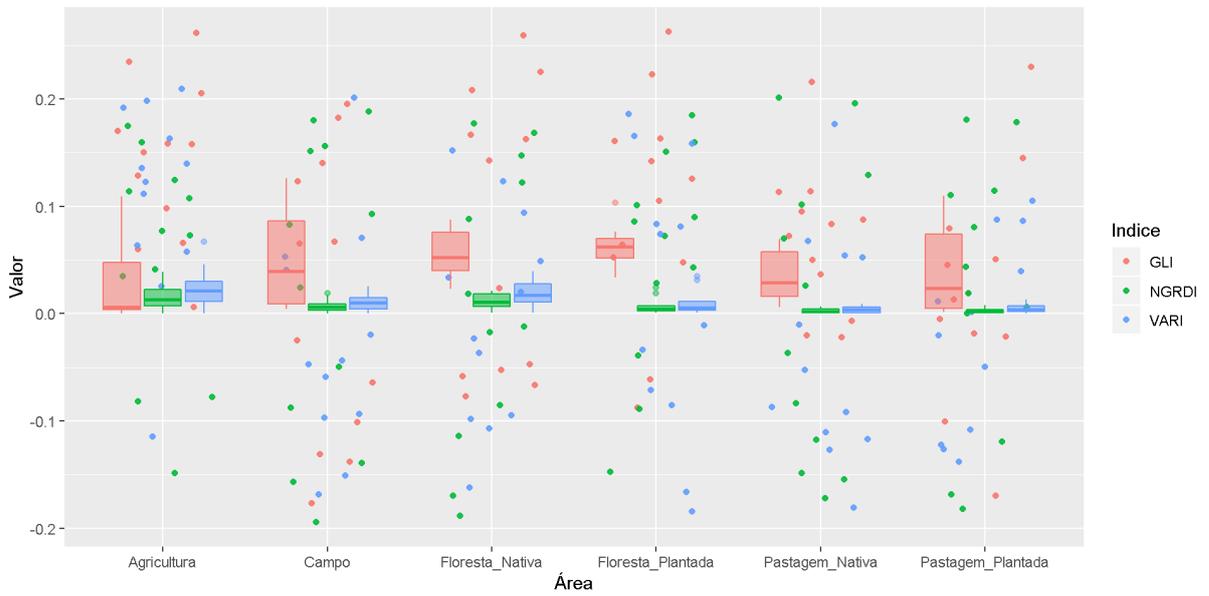
Figura 34 - Análise de significância de contrastes dos índices de vegetação dos dados orbitais agrupados por índices e parcelas amostrais



Fonte: Autor (2019)

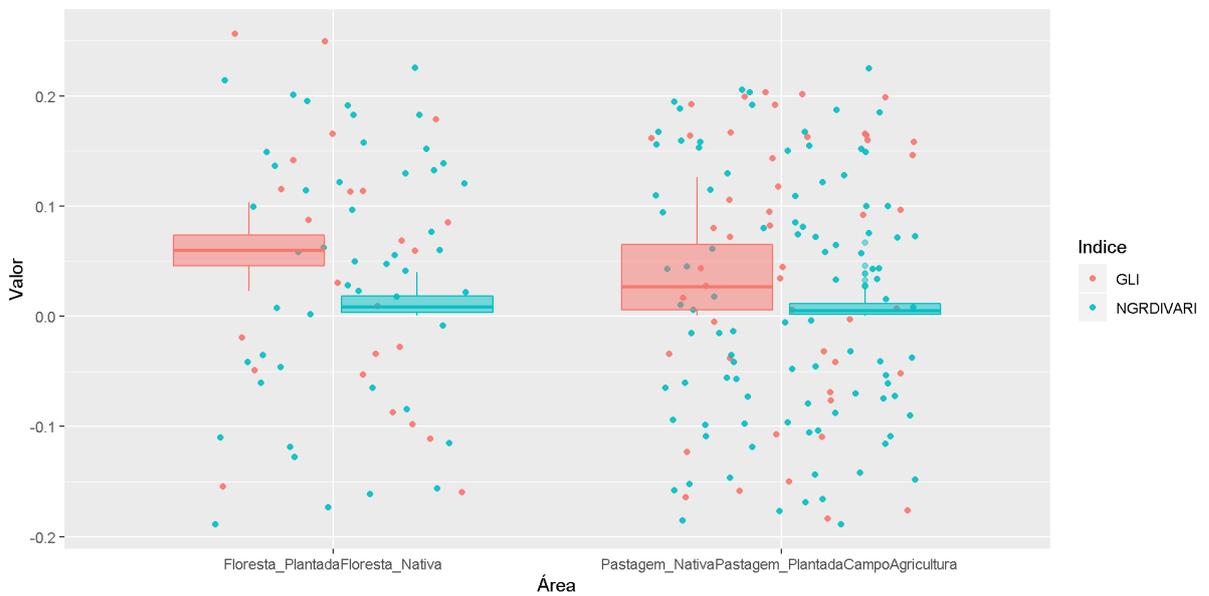
Para os dados aerotransportados, a análise de variância, juntamente com o teste de hipótese, também indicou que houberam diferenças significativas entre as parcelas amostrais ($p\text{-value} < 2e^{-16}$) e os índices de vegetação ($p\text{-value} < 0.011$), a um nível de significância de 5% (Figura 35). Quanto às avaliações de contrastes (Figura 36), foi possível identificar um comportamento semelhante para os índices de vegetação NGRDI-VARI, com média por nível de fator de 0,009 e comportamento distinto para GLI, com média por nível de fator de 0,045. Já para as parcelas amostrais, a agricultura, o campo, a pastagem nativa e a pastagem plantada apresentaram comportamentos semelhantes entre si, com média por níveis de fator de 0,018, enquanto na floresta nativa e a floresta plantada esse comportamento de semelhança também foi observado com média por níveis de fator de 0,027.

Figura 35 - Análise de variância dos índices de vegetação ajustados ao modelo GLM para os dados aerotransportados



Fonte: Autor (2019)

Figura 36 - Análise de significância de contrastes referente aos dados aerotransportados agrupados por índices e parcelas amostrais



Fonte: Autor (2019)

7 CONCLUSÕES

Após serem realizadas uma série de análises sobre os resultados obtidos, é possível fazer algumas considerações específicas no que se refere às peculiaridades encontradas durante o desenvolvimento do presente estudo. No tocante às imagens orbitais, estas apresentaram uma grande riqueza de informações e se mostraram deficientes do ponto de vista da repetitividade, em virtude do alto grau de interferências atmosféricas. Todavia, este é um problema inerente à própria tecnologia, que acaba por inviabilizar o seu uso dentro de um cronograma mais rígido de monitoramento. Apesar do S2A e S2B serem equipamentos novos e com uma ampla gama de possibilidades de aplicações, a dependência de condições atmosféricas ideais, conjugada com as limitações espaciais, acabam por amparar a utilização de RPAs como alternativa para determinados tipos de monitoramento.

Quanto aos dados aerotransportados, estes se mostraram uma alternativa viável para suprir as deficiências de repetitividade e limitações espaciais presentes nos dados orbitais. Entretanto, a aquisição das ortofotos se mostraram totalmente dependentes de condições atmosféricas favoráveis, uma vez que alguns trabalhos de campo tiveram que ser replanejados em busca de melhores condições climáticas. Outro ponto questionável é que a utilização destes equipamentos está relacionada à baixa autonomia que os RPAs de baixo custo apresentam, o que impede o recobrimento de áreas maiores em um único voo. No que se refere ao processamento dos dados obtidos, os aplicativos de fotogrametria demandam ainda uma altíssima capacidade de processamento gráfico, o que inviabiliza o uso de microcomputadores comuns, por serem necessárias estações de trabalho dotadas de hardwares robustos com grande quantidade de memória RAM (idealmente 32 GB ou mais) e placas gráficas igualmente poderosas (6 GB ou mais). Esse fator em específico produz um impacto financeiro inicial substancial no planejamento dos projetos de pesquisa, que muitas vezes pode superar o custo de aquisição da própria RPA. Uma alternativa de processamento seria a utilização de servidores especializados na nuvem (*cloud computing*), comercialmente disponíveis mediante pagamentos por assinatura periódica ou trabalhos individuais. De qualquer forma, esses aspectos devem ser levados em consideração antes da proposição de utilização desses dados como fonte de informação.

Para os comportamentos temporais obtidos com índices de vegetação advindos dos dados orbitais e aerotransportados, esses mostraram-se extremamente semelhantes entre si, apesar de diferenças estatísticas serem observadas em todas as análises desenvolvidas, seja pelas respostas dos índices de vegetação ou pelas parcelas amostrais. Logicamente, algumas

diferenças foram notadas em ambos os conjuntos de dados, uma vez que apresentam características totalmente diferentes de captação. Porém, semelhanças também são notadas, pois a composição variável analisada é igual. No entanto, a aplicação dos índices de vegetação do visível se mostra viável para monitoramentos da vegetação, desde que sejam avaliados parâmetros de validação em campo e definidos os objetivos específicos para as investigações propostas.

Especificamente quanto aos índices de vegetação baseados nos dados orbitais, o NGRDI se mostrou o mais coerente quando comparado ao NDVI, sendo o GLI, por sua vez, o menos coerente. Entretanto, todos os índices orbitais apresentam correlações elevadas quando comparados ao NDVI, abrindo assim uma nova perspectiva de análise, considerando apenas a porção visível do espectro. Para os índices advindos dos dados aerotransportados, apesar de existirem baixas correlações entre eles e o NDVI orbital, o GLI foi considerado o índice que apresentou os melhores resultados, enquanto o VARI teve os piores. Porém, mesmo com resultados de correlações consideradas baixas, os índices advindos dos dados aerotransportados apresentaram comportamentos típicos de cada fitofisionomia, apresentando, assim, grande potencial de aplicação para o monitoramento vegetal.

Considerando os comportamentos que as fitofisionomias apresentaram ao longo do estudo em ambos os conjuntos de dados, foi possível observar também que as formações florestais apresentaram comportamentos estáveis e com baixa variações espectrais durante o período analisado. Ao contrário disso, as vegetações campestres apresentaram variações altamente influenciáveis pelas distribuições sazonais pluviométricas. Já a parcela amostral de agricultura apresentou um comportamento temporal típico dessa vegetação, uma vez que foi possível observar variações advindas do plantio da cultura anual, desenvolvimento das plantas, estágio de senescência, interrupção da cultura e disposição de solo exposto.

Dessa forma, pode-se afirmar que os resultados obtidos com o presente estudo fornecem o conhecimento básico de que é possível realizar estimativas sobre as diferentes fitofisionomias do Cerrado com dados advindos de RPAs equipadas com câmeras RGB convencionais. Essa afirmação pode ser feita com clareza e coerência após realizar uma série de análises e testes estatísticos em um amplo conjunto de dados, concluindo, assim, que os índices de vegetação baseados exclusivamente na porção visível do espectro eletromagnético fornecem informações precisas e valiosas para análises sobre as características da vegetação, com potencial positivo de utilização para monitoramentos.

REFERÊNCIAS

- ABREU, K. M. P. DE; COUTINHO, L. M. Sensoriamento remoto aplicado ao estudo da vegetação com ênfase em índice de vegetação e métricas da paisagem. **Revista Vértices**, v. 16, n. 1, p. 173–198, 2014.
- AGAPIOU, A. et al. Evaluating the potentials of Sentinel-2 for archaeological perspective. **Remote Sensing**, v. 6, p. 2176–2194, 2014.
- AGGARWAL, S. Principles of remote sensing. In: SIVAKUMAR, M. V. K. et al. (Eds.). . **Satellite remote sensing and GIS applications in agricultural meteorology**. Genebra: World Meteorological Organisation, 2004. p. 23–38.
- AMRI, R. et al. Analysis of vegetation behavior in a North African semi-arid region, Using SPOT-VEGETATION NDVI data. **Remote Sensing**, v. 3, n. 12, p. 2568–2590, 29 nov. 2011.
- ANA. **Séries históricas de estações**. Disponível em: <http://www.snirh.gov.br/hidroweb/publico/medicoes_historicas_abas.jsf>. Acesso em: 28 fev. 2019.
- ANAC. Orientações para usuários de drones. **Assessoria de Comunicação Social - ASCOM**, 2017.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 6.028 - Informação e documentação - Resumo - Apresentação. 2003.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 14.724 - Informação e documentação - Trabalhos acadêmicos - Apresentação. 2011.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR 6.023 - Informação e documentação - Referências - Elaboração. 2018.
- ATZBERGER, C.; RICHTER, K. Spatially constrained inversion of radiative transfer models for improved LAI mapping from future Sentinel-2 imagery. **Remote Sensing of Environment**, v. 120, p. 208–218, 15 maio 2012.
- BALLESTEROS, R. et al. Combined use of agro-climatic and very high-resolution remote sensing information for crop monitoring. **International Journal of Applied Earth Observation and Geoinformation**, v. 72, n. May, p. 66–75, 2018.
- BERNI, J. A. J. et al. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722–738, mar. 2009a.
- BERNI, J. A. J. et al. Mapping canopy conductance and CWSI in olive orchards using high resolution thermal remote sensing imagery. **Remote Sensing of Environment**, v. 113, n. 11, p. 2380–2388, 16 nov. 2009b.
- BOHRER, C. B. D. A. et al. Mapeamento da vegetação e do uso do solo no Centro de Diversidade Vegetal de Cabo Frio, Rio de Janeiro, Brazil. **Rodriguésia**, v. 60, n. 1, p. 1–23, 2009.
- BOHRER, C. B. DE A. Vegetação, paisagem e o planejamento do uso da terra. **GEOgraphia**, v. 2, n. 4, p. 103, 16 set. 2000.
- BOOTH, D. T.; COX, S. E. Art to science: Tools for greater objectivity in resource monitoring. **Rangelands**, v. 33, n. 4, p. 27–34, 2011.
- BORRÀS, J. et al. Clasificación de usos del suelo a partir de imágenes Sentinel-2. **Revista de Teledeteccion**, v. 2017, n. 48, p. 55–66, 2017.
- BRECKENRIDGE, R. P. et al. Comparison of unmanned aerial vehicle platforms for assessing vegetation cover in sagebrush steppe ecosystems. **Rangeland Ecology and Management**, v. 64, n. 5, p. 521–532, 1 set. 2011.
- BUENO, I. et al. Object-Based Change Detection in the Cerrado Biome Using Landsat Time Series.

Remote Sensing, v. 11, n. 5, p. 570, 8 mar. 2019.

CALLEGARI-JACQUES, S. M. **Bioestatística - Princípios e Aplicações**. Porto Alegre: Artmed, 2003.

CÂNDIDO, A. K. A. A.; SILVA, N. M. DA; PARANHOS-FILHO, A. C. Imagens de alta resolução espacial de Veículos Aéreos Não Tripulados (VANT) no planejamento do uso e ocupação do solo. **Anuario do Instituto de Geociências**, v. 38, n. 1, p. 147–156, 2015.

CARDOZO, F. DA S. et al. Using remote sensing products for environmental analysis in South America. **Remote Sensing**, v. 3, n. 10, p. 2110–2127, 26 set. 2011.

CARRÃO, H. et al. Carta de ocupação do solo e avaliação do estado da vegetação com imagens de satélite para prevenção de fogos florestais. **Anais do VII Encontro de Utilizadores de Informação Geográfica**, p. 13–15, 2002.

CARVALHO-JÚNIOR, O. A. DE et al. Classificação de padrões de savana usando assinaturas temporais NDVI do sensor MODIS no Parque Nacional Chapada dos Veadeiros. **Revista Brasileira de Geofísica**, v. 26, n. 4, p. 505–517, 2010.

CARVALHO, F. M. V.; MARCO-JÚNIOR, P. DE; FERREIRA, L. G. The Cerrado into-pieces: Habitat fragmentation as a function of landscape use in the savannas of central Brazil. **Biological Conservation**, v. 142, n. 7, p. 1392–1403, jul. 2009.

CHENG, H. D. et al. Color image segmentation: Advances and prospects. **Pattern Recognition**, v. 34, n. 12, p. 2259–2281, 2001.

CLEVERS, J. G. P. W.; GITELSON, A. A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 344–351, 1 ago. 2013.

COHEN, W. B. et al. Comparisons of land cover and LAI estimates derived from ETM+ and MODIS for four sites in North America: a quality assessment of 2000/2001 provisional MODIS products. **Remote Sensing of Environment**, v. 88, n. 3, p. 233–255, dez. 2003.

COLWELL, R. N. From photographic interpretation to remote sensing introduction. **Photogrammetric Engineering and Remote Sensing**, v. 50, n. 9, p. 1305–1307, 1984.

CORBANE, C. et al. Multitemporal analysis of hydrological soil surface characteristics using aerial photos: A case study on a mediterranean vineyard. **International Journal of Applied Earth Observation and Geoinformation**, v. 18, n. 1, p. 356–367, 1 ago. 2012.

CÓRCOLES, J. I. et al. Estimation of leaf area index in onion (*Allium cepa* L.) using an unmanned aerial vehicle. **Biosystems Engineering**, v. 115, n. 1, p. 31–42, maio 2013.

CPRM. **Projeto Vazante - Paracatu, Estado de Minas Gerais e Goiás: texto explicativo**. Belo Horizonte: CPRM-BH, 2017.

CRAWLEY, M. J. **The R book**. Chichester: John Wiley & Sons, 2007.

CRISTALDO, P. F. et al. Heterospecific detection of host alarm cues by an inquiline termite species (Blattodea: Isoptera: Termitidae). **Animal Behaviour**, v. 120, p. 43–49, 2016.

D'OLEIRE-OLTMANN, S. et al. Unmanned aerial vehicle (UAV) for monitoring soil erosion in Morocco. **Remote Sensing**, v. 4, n. 11, p. 3390–3416, 7 nov. 2012.

DJI. **Phantom 4**. Disponível em: <<https://www.dji.com/phantom-4>>. Acesso em: 3 nov. 2018.

DRUSCH, M. et al. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote Sensing of Environment**, v. 120, p. 25–36, maio 2012.

EISENBEISS, H.; ZHANG, L. Comparison of DSMS generated from mini UAV imagery and terrestrial laser scanner in a cultural heritage application. **ISPRS Commission V Symposium "Image Engineering and Vision Metrology"**, v. 36, n. 5, p. 90–96, 2006.

- EMERY, W. J.; CAMPS, A. **Introduction to satellite remote sensing: atmosphere, ocean, land and cryosphere applications**. 1. ed. Amsterdam: Elsevier, 2017.
- ESA. **GMES Sentinel-2 mission requirements document (EOP-SM/1163/MR-dr, ed. 2, rev. 1)**, 2010a.
- ESA. **GMES space component products definition document (GMES-GSEG-EOPG-TN-09-0029, ed. 1, rev. 2)**, 2010b.
- ESA. **Sentinel-2**. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 22 jan. 2019a.
- ESA. **Copernicus**. Disponível em: <http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Overview4>. Acesso em: 21 jan. 2019b.
- ESA. **Copernicus open access hub**. Disponível em: <<https://scihub.copernicus.eu/dhus/#/home>>. Acesso em: 22 jan. 2019c.
- ESRI. **ArcGIS Desktop 10.5.0.6491**. Redlands, 2016.
- EU. Regulation European nº 911/2010 of the European Parliament and of the Council of 22 September 2010 on the European Earth monitoring programme (GMES) and its initial operations (2011 to 2013). p. 1–10, 2010.
- EU. Regulation European nº 377/2014 of the European Parliament and of the Council of 3 April 2014 establishing the Copernicus Programme and repealing Regulation (EU) nº 911/2010. v. 2014, n. 377, p. 44–66, 2014.
- FANG, S. et al. Remote Estimation of Vegetation Fraction and Flower Fraction in Oilseed Rape with Unmanned Aerial Vehicle Data. **Remote Sensing**, v. 8, n. 5, p. 416, 16 maio 2016.
- FERREIRA, L. G. et al. Use of orbital LIDAR in the Brazilian cerrado biome: Potential applications and data availability. **Remote Sensing**, v. 3, n. 10, p. 2187–2206, 17 out. 2011.
- FERREIRA, L. G.; FERREIRA, N. C.; FERREIRA, M. E. Sensoriamento remoto da vegetação: evolução e estado da arte. **Acta Scientiarum - Biological Sciences**, v. 30, n. 4, p. 379–390, 2008.
- FERREIRA, L. G.; HUETE, A. R. Assessing the seasonal dynamics of the Brazilian Cerrado vegetation through the use of spectral vegetation indices. **International Journal of Remote Sensing**, v. 25, n. 10, p. 1837–1860, 2 maio 2004.
- FERREIRA, M. E. et al. Análise comparativa dos produtos MODIS ecologia para o monitoramento biofísico ambiental do bioma cerrado. **Revista Brasileira de Geofísica**, v. 24, n. 2, p. 251–260, 2006.
- FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002.
- FLORENZANO, T. G. **Os Satélites e suas aplicações**. São José dos Campos: SindCT, 2008.
- FRAMPTON, W. J. et al. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 82, p. 83–92, 1 ago. 2013.
- FUSSELL, J.; RUNDQUIST, D. C.; HARRINGTON-JR., J. A. On defining remote sensing. **Photogrammetric Engineering and Remote Sensing**, v. 52, n. 9, p. 1507–1511, 1986.
- GETZIN, S.; WIEGAND, K.; SCHÖNING, I. Assessing biodiversity in forests using very high-resolution images and unmanned aerial vehicles. **Methods in Ecology and Evolution**, v. 3, n. 2, p. 397–404, 1 abr. 2012.
- GIBBS, H. K.; SALMON, J. M. **Mapping the world's degraded lands** *Applied Geography*, fev. 2015. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0143622814002793>>. Acesso em: 12 mar. 2019

- GITELSON, A. A. et al. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76–87, 2002.
- GITELSON, A. A. et al. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, v. 30, n. 5, p. n/a-n/a, 2003.
- GOEDERT, W. J. Região dos Cerrados: potencial agrícola e política para seu desenvolvimento. **Pesquisa Agropecuária Brasileira**, v. 24, n. 1, p. 1–17, 1989.
- HARDIN, P. J. et al. Small Unmanned Aerial Systems (sUAS) for environmental remote sensing: challenges and opportunities revisited. **GIScience and Remote Sensing**, 2018.
- HARDIN, P. J.; JENSEN, R. R. Small-Scale Unmanned Aerial Vehicles in Environmental Remote Sensing: Challenges and Opportunities. **GIScience & Remote Sensing**, v. 48, n. 1, p. 99–111, 15 jan. 2011.
- HARWIN, S.; LUCIEER, A. Assessing the accuracy of georeferenced point clouds produced via multi-view stereopsis from Unmanned Aerial Vehicle (UAV) imagery. **Remote Sensing**, v. 4, n. 6, p. 1573–1599, 30 maio 2012.
- HEDLEY, J. et al. Capability of the Sentinel 2 mission for tropical coral reef mapping and coral bleaching detection. **Remote Sensing**, v. 120, p. 145–155, 15 maio 2012.
- HERVOUET, A. et al. Analysis of post-flood recruitment patterns in braided-channel rivers at multiple scales based on an image series collected by Unmanned Aerial Vehicles, Ultra-light Aerial Vehicles, and Satellites. **GIScience & Remote Sensing**, v. 48, n. 1, p. 50–73, 15 jan. 2011.
- HILL, M. J. Vegetation index suites as indicators of vegetation state in grassland and savanna: an analysis with simulated Sentinel-2 data for a North American transect. **Remote Sensing of Environment**, v. 137, p. 94–111, out. 2013.
- HOUSE, F. B. et al. History of satellite missions and measurements of the Earth Radiation Budget (1957–1984). **Reviews of Geophysics**, v. 24, n. 2, p. 357–377, 1986.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing**, v. 25, n. 3, p. 295–309, 1988.
- HUETE, A. R. et al. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440–451, mar. 1997.
- HUETE, A. R. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 195–213, 2002.
- HUNT-JR, E. R. et al. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, n. 4, p. 359–378, ago. 2005.
- HUNT-JR, E. R. et al. Remote sensing leaf chlorophyll content. **Agronomy Journal**, v. 103, n. 2, p. 1090–1099, 2011a.
- HUNT-JR, E. R. et al. NIR-Green-Blue High-Resolution Digital Images for Assessment of Winter Cover Crop Biomass. **GIScience & Remote Sensing**, v. 48, n. 1, p. 86–98, 15 jan. 2011b.
- IBGE. **IBGE Cidades**. Disponível em: <<https://cidades.ibge.gov.br/brasil/mg/patos-de-minas/panorama>>. Acesso em: 20 nov. 2018.
- INFATICS, I. **DroneDeploy - Mapping dor DJI**, 2016. Disponível em: <<https://itunes.apple.com/br/app/dronedeploy-mapping-for-dji/id971358101?mt=8>>
- JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. 2. ed. São José dos Campos: Editora Parêntese, 2009.
- JONES-IV, G. P.; PEARLSTINE, L. G.; PERCIVAL, H. F. An assessment of small Unmanned Aerial Vehicles for wildlife research. **Wildlife Society Bulletin**, v. 34, n. 3, p. 750–758, 2006.
- JORDAN, C. F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, 1969.

- KANEMASU, E. T. Seasonal canopy reflectance patterns of wheat, sorghum, and soybean. **Remote Sensing of Environment**, v. 3, n. 1, p. 43–47, jan. 1974.
- KAUFMAN, Y. J.; TANRÉ, D. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261–270, mar. 1992.
- KÖPPEN, W. P. **Klimate der erde: grundriss der klimakunde**. Berlin: Justus Perthes, 1923.
- KUMAR, R. R. **Radiation from plants, reflection and emission: a review**. Lafayette: Purdue Research Foundation, 1972.
- LALIBERTE, A. S. et al. Multispectral remote sensing from unmanned aircraft: Image processing workflows and applications for rangeland environments. **Remote Sensing**, v. 3, n. 11, p. 2529–2551, 22 nov. 2011.
- LEBOURGEOIS, V. et al. Can commercial digital cameras be used as multispectral sensors? A crop monitoring test. **Sensors**, v. 8, n. 11, p. 7300–7322, 2008.
- LIU, M. et al. Heavy metal-induced stress in rice crops detected using multi-temporal Sentinel-2 satellite images. **Science of the Total Environment**, v. 637–638, p. 18–29, 2018.
- LLC, A. **Agisoft Metashape Professional Edition 1.5**. Saint Petersburg, 2018.
- LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**, v. 16, n. 1, p. 65–70, 2 mar. 2001.
- MAIO, A. DI et al. **Curso Astronáutica e ciências do espaço: sensoriamento remoto**. São José dos Campos: AEB Escola, 2008.
- MARQUES, C. S. S. et al. Geologia e quimioestratigrafia isotópica do grupo Vazante em Lagamar (MG). **Revista Geonomos**, v. 23, n. 1, p. 26–41, 2015.
- MELESSE, A. M. et al. Remote sensing sensors and applications in environmental resources mapping and modelling. **Sensors**, v. 7, p. 3209–3241, 2007.
- MENESES, P. R. Fundamentos de radiometria óptica espectral. In: MENESES, P. R.; NETTO, J. DA S. M. (Eds.). . **Sensoriamento remoto: refletância dos alvos naturais**. Brasília: Editora Universidade de Brasília, 2001. p. 15–40.
- MENESES, P. R. Princípios do sensoriamento remoto. In: MENESES, P. R.; ALMEIDA, T. DE (Eds.). . **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: Universidade de Brasília, 2012. p. 1–31.
- MMA. **O bioma Cerrado**. Disponível em: <<http://www.mma.gov.br/biomas/cerrado>>. Acesso em: 11 mar. 2019.
- MORAES, E. C. DE. Fundamentos de sensoriamento remoto. In: RUDORFF, B. F. T. et al. (Eds.). . **Curso de uso de sensoriamento remoto no estudo do meio ambiente**. São José dos Campos: INPE, 2002. p. 1–22.
- MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4. ed. Viçosa: Editora Universidade Federal de Viçosa, 2011.
- MÜLLER-WILM, U. Sen2Cor configuration and user manual (S2-PDGS-MPC-L2A-SUM-V2.5.5). p. 54, 2018.
- MYERS, N. et al. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853–858, 24 fev. 2000.
- NASA. **TIROS, the nation's first weather satellite**. Disponível em: <https://www.nasa.gov/multimedia/imagegallery/image_feature_1627.html>. Acesso em: 24 jan. 2019.

- NEWCOME, L. R. **Unmanned aviation: a brief history of unmanned aerial vehicles**. Reston ,VA: American Institute of Aeronautics and Astronautics, 2004.
- NOVO, E. M. L. DE M. **Sensoriamento remoto: princípios e aplicações**. 4. ed. São Paulo: Blucher, 2010.
- NOVO, E. M. L. DE M.; PONZONI, F. J. **Introdução ao sensoriamento remoto**. São José dos Campos: INPE, 2001.
- NUNES, G. M.; SOUZA-FILHO, C. R. DE; FERREIRA, L. G. Discriminação de fitofisionomias na Amazônia central por meio de índices de vegetação de imagens com resolução espacial moderada. **Revista Geografia Acadêmica**, v. 6, n. 1, p. 5–14, 2012.
- NYQUIST, J. E. **Applications of Low-Cost Radio-Controlled Airplanes to Environmental Restoration at Oak Ridge National Laboratory**. [s.l.: s.n.]. Disponível em: <https://inis.iaea.org/collection/NCLCollectionStore/_Public/28/012/28012573.pdf>. Acesso em: 16 fev. 2019.
- PADRÓ, J.-C. et al. Radiometric Correction of Landsat-8 and Sentinel-2A Scenes Using Drone Imagery in Synergy with Field Spectroradiometry. **Remote Sensing**, v. 10, n. 11, p. 1687, 2018.
- PANEQUE-GÁLVEZ, J. et al. Small drones for community-based forest monitoring: An assessment of their feasibility and potential in tropical areas. **Forests**, v. 5, n. 6, p. 1481–1507, 2014.
- PÔÇAS, I. et al. Predicting grapevine water status based on hyperspectral reflectance vegetation indices. **Remote Sensing**, v. 7, n. 12, p. 16460–16479, 5 dez. 2015.
- PONZONI, F. J. Comportamento espectral da vegetação. In: MENESES, P. R.; NETTO, J. DA S. M. (Eds.). **Sensoriamento remoto: refletância dos alvos naturais**. Brasília: Universidade de Brasília, 2001. p. 157–199.
- PONZONI, F. J. Sensoriamento remoto no estudo da vegetação: diagnosticando a Mata Atlântica. In: **Curso de uso de sensoriamento remoto no estudo do meio ambiente**. São José dos Campos: INPE, 2002. p. 1–27.
- PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. 1. ed. São José dos Campos: Editora Parêntese, 2007.
- QUILTER, M. C.; ANDERSON, V. J. Low altitude/large scale aerial photographs: a tool for range and resource managers. **Rangelands**, v. 22, n. 2, p. 13–17, 2016.
- RANGO, A. et al. Using unmanned aerial vehicles for rangelands: Current applications and future potentials. **Environmental Practice**, v. 8, n. 3, p. 159–168, 27 set. 2006.
- RANGO, A. et al. Unmanned aerial vehicle-based remote sensing for rangeland assessment, monitoring, and management. **Journal of Applied Remote Sensing**, v. 3, n. 1, p. 033542, 1 ago. 2009.
- RANI, N.; MANDLA, V. R.; SINGH, T. Evaluation of atmospheric corrections on hyperspectral data with special reference to mineral mapping. **Geoscience Frontiers**, v. 8, n. 4, p. 797–808, jul. 2017.
- RIBEIRO, J. F.; WALTER, B. M. T. Fitofisionomias do bioma cerrado. In: SANO, S. M.; ALMEIDA, S. P. DE (Eds.). **Cerrado: ambiente e flora**. Planaltina: EMBRAPA-CPAC, 1998. p. 89–166.
- RICHTER, K. et al. Experimental assessment of the Sentinel-2 band setting for RTM-based LAI retrieval of sugar beet and maize. **Canadian Journal of Remote Sensing**, v. 35, n. 3, p. 230–247, 2 jan. 2009.
- RICHTER, K. et al. Optimal exploitation of the Sentinel-2 spectral capabilities for crop leaf area index mapping. **Remote Sensing**, v. 4, n. 3, p. 561–582, 28 fev. 2012.
- RICHTER, R.; SCHLÄPFER, D. **ATCOR-2/3 user guide, v.9.0.2**. Disponível em: <http://www.rese.ch/pdf/atcor3_manual.pdf>. Acesso em: 15 nov. 2018.

- RODRÍGUEZ, A. et al. The Eye in the Sky: Combined Use of Unmanned Aerial Systems and GPS Data Loggers for Ecological Research and Conservation of Small Birds. **PLoS ONE**, v. 7, n. 12, p. e50336, 11 dez. 2012.
- ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. **Third Earth Resources Technology Satellite (ERTS) symposium**, v. 1, p. 309–317, 1974.
- SABERIOON, M. M. et al. Assessment of rice leaf chlorophyll content using visible bands at different growth stages at both the leaf and canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 32, n. 1, p. 35–45, 2014.
- SALAMA, M. S.; RADWAN, M.; VAN DER VELDE, R. A hydro-optical model for deriving water quality variables from satellite images (HydroSat): A case study of the Nile River demonstrating the future Sentinel-2 capabilities. **Physics and Chemistry of the Earth**, v. 50–52, p. 224–232, 1 jan. 2012.
- SANO, E. E. et al. Land cover mapping of the tropical savanna region in Brazil. **Environmental Monitoring and Assessment**, v. 166, n. 1–4, p. 114–124, 6 jul. 2009.
- SARDÀ-PALOMERA, F. et al. Fine-scale bird monitoring from light unmanned aircraft systems. **Ibis**, v. 154, n. 1, p. 177–183, 1 jan. 2012.
- SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, 1965.
- SHIMABUKURO, Y. E.; MAEDA, E. E.; FORMAGGIO, A. R. Sensoriamento remoto e sistemas de informações geográficas aplicados ao estudo dos recursos agrônômicos e florestais. **Revista Ceres**, v. 56, n. 4, p. 399–409, 2009.
- SLATER, P. N. **Remote sensing: optics and optical systems**. New Jersey: Addison-Wesley, 1980.
- SMITHSONIAN. **Landsat 1 (ERTS-A, ERTS-1)**. Disponível em: <<https://airandspace.si.edu/collection-objects/landsat-1-erts-erts-1-photograph-0>>. Acesso em: 24 jan. 2019.
- SOLUTIONS, H. G. **ENVI 5.3**. Boulder, 2015.
- SOPCHAKI, C. H. et al. Verificação da qualidade de ortomosaicos produzidos a partir de imagens obtidas com aeronava remotamente pilotada sem uso de pontos de apoio. **Ra'eGa**, v. 43, p. 200–214, 2018.
- SOUSA, H. L. DE. Sensoriamento Remoto com VANTs: uma nova possibilidade para a aquisição de geoinformações. **Revista Brasileira de Geomática**, v. 5, n. 3, p. 326–342, 2017.
- SPEARMAN, C. The proof and measurement of association between two things. **The American journal of psychology****The American Journal of Psychology**, v. 15, n. 1, p. 72–101, 1904.
- TEAM, RS. **RStudio: Integrated Development for R**Boston:RStudio, Inc., , 2015. Disponível em: <<http://www.rstudio.com/>>. Acesso em: 11 nov. 2018
- TOMLINS, G. F. Some Considerations in the Design of Low-Cost Remotely- Piloted Aircraft for Civil Remote Sensing Applications. **The Canadian Surveyor**, v. 37, p. 157–167, 1983.
- TORMAN, V. B. L.; COSTER, R.; RIBOLDI, J. Normalidade de variáveis: métodos de verificação e comparação de alguns testes não-paramétricos por simulação. **Revista HCPA**, v. 32, n. 2, p. 227–234, 2012.
- TORRADO, J. O. E.-; CÁCERES, J. J. J.; DÍAZ, H. P. Ortomosaicos y modelos digitales de elevación generados a partir de imágenes tomadas con sistemas UAV. **Tecnura**, v. 20, n. 50, p. 119–140, 2016.
- TORRES-SÁNCHEZ, J. et al. Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. **Computers and Electronics in Agriculture**, v. 103, p. 104–113, abr. 2014.

- TRENTIN, A. B.; SALDANHA, D. L.; KUPLICH, T. M. Análise comparativa do NDVI em fitofisionomias na bacia hidrográfica do rio São Marcos. **Revista Geográfica Acadêmica**, v. 7, n. 1, p. 5–16, 2013.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, p. 127–150, 1979.
- TURNER, D. et al. An Automated Technique for Generating Georectified Mosaics from Ultra-High Resolution Unmanned Aerial Vehicle (UAV) Imagery, Based on Structure from Motion (SfM) Point Clouds. **Remote Sensing**, v. 4, n. 5, p. 1392–1410, 14 maio 2012.
- USGS. **EarthExplorer - Home**. Disponível em: <<https://earthexplorer.usgs.gov/>>. Acesso em: 22 jan. 2019.
- VAN DER MEER, F. D.; VAN DER WERFF, H. M. A.; VAN RUITENBEEK, F. J. A. Potential of ESA's Sentinel-2 for geological applications. **Remote Sensing of Environment**, v. 148, p. 124–133, 2014.
- VAN DER WERFF, H. M. A.; VAN DER MEER, F. D. Sentinel-2 for mapping iron absorption feature parameters. **Remote Sensing**, v. 7, n. 10, p. 12635–12653, 2015.
- VIECILI, F. L. **Sensoriamento remoto aplicado ao mapeamento temático do uso e cobertura do solo ba bacia do Caeté, município de Alfredo Wagner, SC**. Dissertação (Mestrado em Gestão Ambiental em Bacias Hidrográficas). Florianópolis: Universidade Federal de Santa Catarina, 2005.
- WAN, L. et al. Combining UAV-Based Vegetation Indices and Image Classification to Estimate Flower Number in Oilseed Rape. **Remote Sensing**, v. 10, n. 9, p. 1484, 2018.
- WANG, Y. et al. Evaluation of the MODIS LAI algorithm at a coniferous forest site in Finland. **Remote Sensing of Environment**, v. 91, n. 1, p. 114–127, maio 2004.
- WANG, Z. X.; LIU, C.; HUETE, A. From AVHRRNDVI to MODIS-EVI: advances in vegetation index research. **Acta Ecologica Sinica**, v. 23, n. 5, p. 989–988, 2003.
- WATTS, A. C. et al. Small Unmanned Aircraft Systems for Low-Altitude Aerial Surveys. **Journal of Wildlife Management**, v. 74, n. 7, p. 1614–1619, set. 2010.
- WENG, Q. **Remote Sensing and GIS Integration: Theories, Methods, and Applications**. New York: McGraw-Hill, 2010.
- WHITESIDE, T. G.; BARTOLO, R. E. Mapping aquatic vegetation in a tropical wetland using high spatial resolution multispectral satellite imagery. **Remote Sensing**, v. 7, n. 9, p. 11664–11694, 11 set. 2015.
- WUNDRAM, D.; LÖFFLER, J. High-resolution spatial analysis of mountain landscapes using a low-altitude remote sensing approach. **International Journal of Remote Sensing**, v. 29, n. 4, p. 961–974, 21 fev. 2008.
- ZANZARINI, F. V et al. Correlação espacial do índice de vegetação (NDVI) de imagem Landsat/ETM+ com atributos do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 6, p. 608–614, 2013.
- ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, v. 13, n. 6, p. 693–712, 31 dez. 2012.
- ZHENG, H. et al. Evaluation of RGB, color-infrared and multispectral images acquired from unmanned aerial systems for the estimation of nitrogen accumulation in rice. **Remote Sensing**, v. 10, n. 6, p. 824, 25 maio 2018.
- ZHOU, X. et al. Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 246–255, 2017.

ZHU, J. et al. **Quantifying Nitrogen Status of Rice Using Low Altitude UAV-Mounted System and Object-Oriented Segmentation Methodology**. International Design Engineering Technical Conferences & Computers and Information in Engineering Conferenc. **Anais**. 2009.

APÊNDICE A - IMAGENS AEROTRANSPORTADAS**Figura 37** - Agricultura 28/02/2018 (dia 28)**Figura 38** - Agricultura 31/03/2018 (dia 59)**Figura 39** - Agricultura 30/04/2018 (dia 89)**Figura 40** - Agricultura 31/05/2018 (dia 120)

Figura 41 - Agricultura 30/06/2018 (dia 150)



Figura 42 - Agricultura 31/07/2018 (dia 181)



Figura 43 - Agricultura 31/08/2018 (dia 212)



Figura 44 - Agricultura 30/09/2018 (dia 242)



Figura 45 - Agricultura 31/10/2018 (dia 273)



Figura 46 - Agricultura 30/11/2018 (dia 303)



Figura 47 - Agricultura 31/12/2018 (dia 334)



Figura 48 - Agricultura 31/01/2019 (dia 365)



Figura 49 - Campo 28/02/2018 (dia 28)



Figura 50 - Campo 31/03/2018 (dia 59)



Figura 51 - Campo 30/04/2018 (dia 89)

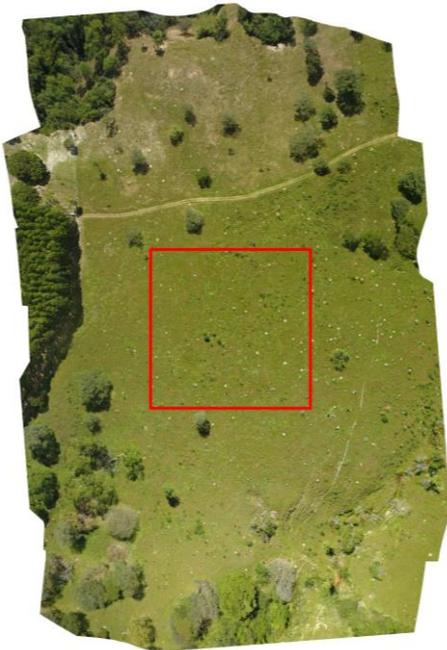


Figura 52 - Campo 31/05/2018 (dia 120)



Figura 53 - Campo 30/06/2018 (dia 150)



Figura 54 - Campo 31/07/2018 (dia 181)



Figura 55 - Campo 31/08/2018 (dia 212)



Figura 56 - Campo 30/09/2018 (dia 242)



Figura 57 - Campo 31/10/2018 (dia 273)



Figura 58 - Campo 30/11/2018 (dia 303)



Figura 59 - Campo 31/12/2018 (dia 334)



Figura 60 - Campo 31/01/2019 (dia 365)



Figura 61 - Floresta nativa e pastagem plantada
28/02/2018 (dia 28)



Figura 62 - Floresta nativa e pastagem plantada
31/03/2018 (dia 59)



Figura 63 - Floresta nativa e pastagem plantada
30/04/2018 (dia 89)



Figura 64 - Floresta nativa e pastagem plantada
31/05/2018 (dia 120)

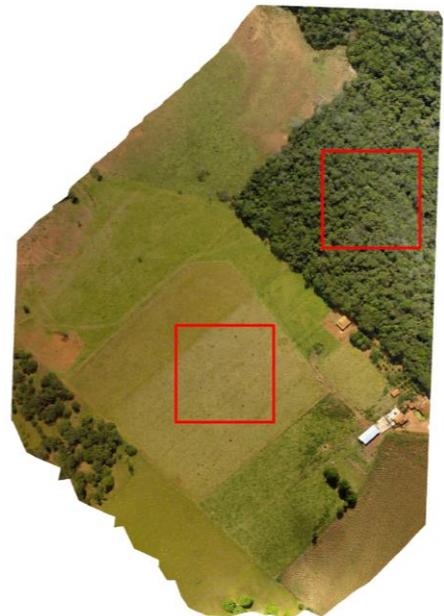


Figura 65 - Floresta nativa e pastagem plantada
30/06/2018 (dia 150)



Figura 66 - Floresta nativa e pastagem plantada
31/07/2018 (dia 181)



Figura 67 - Floresta nativa e pastagem plantada
31/08/2018 (dia 212)



Figura 68 - Floresta nativa e pastagem plantada
30/09/2018 (dia 242)



Figura 69 - Floresta nativa e pastagem plantada
31/10/2018 (dia 273)



Figura 70 - Floresta nativa e pastagem plantada
30/11/2018 (dia 303)



Figura 71 - Floresta nativa e pastagem plantada
31/12/2018 (dia 334)



Figura 72 - Floresta nativa e pastagem plantada
31/01/2019 (dia 365)



Figura 73 - Floresta plantada 28/02/2018 (dia 28)



Figura 74 - Floresta plantada 31/03/2018 (dia 59)



Figura 75 - Floresta plantada 30/04/2018 (dia 89)

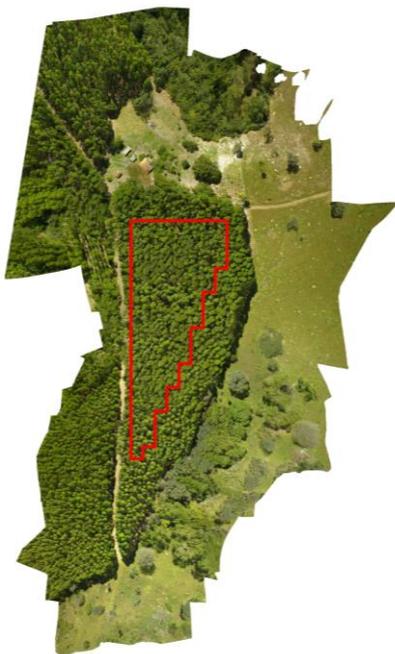


Figura 76 - Floresta plantada 31/05/2018 (dia 120)



Figura 77 - Floresta plantada 30/06/2018 (dia 150)



Figura 78 - Floresta plantada 31/07/2018 (dia 181)



Figura 79 - Floresta plantada 31/08/2018 (dia 212)



Figura 80 - Floresta plantada 30/09/2018 (dia 242)



Figura 81 - Floresta plantada 31/10/2018 (dia 273)



Figura 82 - Floresta plantada 30/11/2018 (dia 303)



Figura 83 - Floresta plantada 31/12/2018 (dia 334)



Figura 84 - Floresta plantada 31/01/2019 (dia 365)



Figura 85 - Pastagem nativa 28/02/2018 (dia 28)

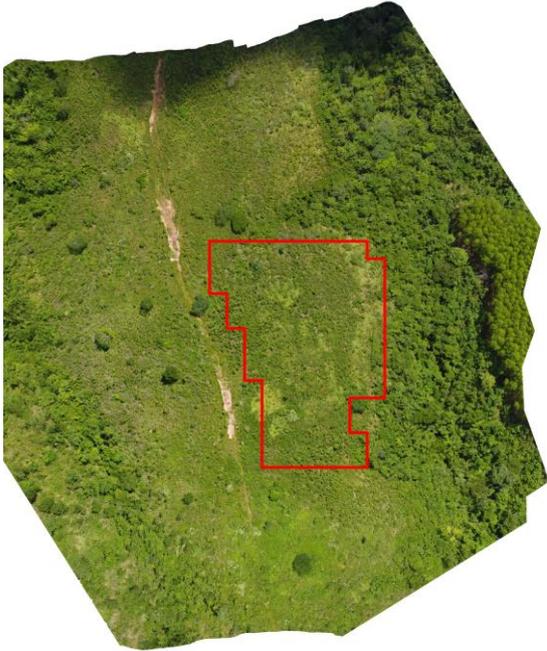


Figura 86 - Pastagem nativa 31/03/2018 (dia 59)

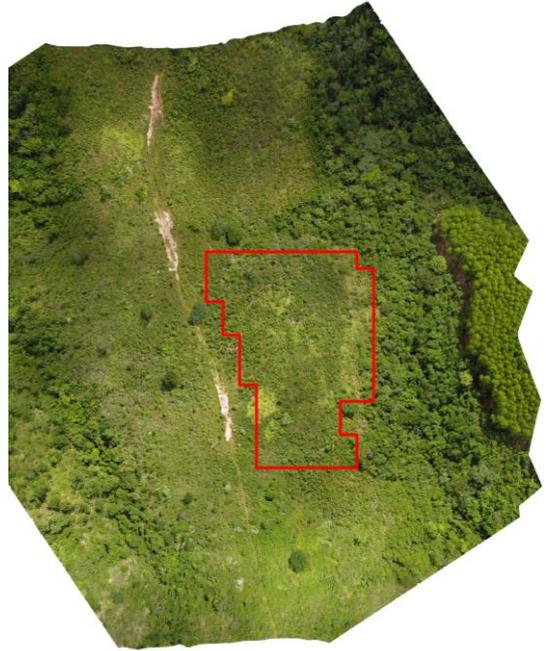


Figura 87 - Pastagem nativa 30/04/2018 (dia 89)



Figura 88 - Pastagem nativa 31/05/2018 (dia 120)



Figura 89 - Pastagem nativa 30/06/2018 (dia 150)



Figura 90 - Pastagem nativa 31/07/2018 (dia 181)



Figura 91 - Pastagem nativa 31/08/2018 (dia 212)



Figura 92 - Pastagem nativa 30/09/2018 (dia 242)



Figura 93 - Pastagem nativa 31/10/2018 (dia 273)



Figura 94 - Pastagem nativa 30/11/2018 (dia 303)



Figura 95 - Pastagem nativa 31/12/2018 (dia 334)



Figura 96 - Pastagem nativa 31/01/2019 (dia 365)



APÊNDICE B - ANÁLISE ESTATÍSTICA

APÊNDICE B.1 - SCRIPT

```

---
title: "ANÁLISE ESTATÍSTICA"
output:
  word_document: default
  pdf_document: default
---

```{r setup, include=FALSE}
knitr::opts_chunk$set(echo = TRUE)
```

# Instalando os packs

install.packages("mosaic");
install.packages("BBmisc");
install.packages("ggplot2");
install.packages("MASS");

# Carregando os dados

```{r}
dados <- read.delim("LOCAL DOS DADOS")
```

```{r,echo=FALSE}
diagnosticoModelo <- function(object) {

nmodels<-NULL
warning about the nmodels argument
if(is.null(nmodels)!=TRUE) {
 warning("nmodels' argument is not necessary anymore, ?rdiagnostic for more information")
}

Make a list of models to be tested
objects <- list(object)

Define if this is plotted
par(mfrow=c(length(objects),2),pty="s",cex.axis=1.5,cex.lab=1.5)

for(model in objects) {
 ##For Gaussian
 if(model$family$family=="gaussian") {
 main <- "Gaussian Model"
 X <- model.matrix(model)
n <- nrow(X)
p <- ncol(X)
H <- X%%solve(t(X)%%X)%%t(X)
h <- diag(H)
si <- lm.influence(model)$sigma
r <- resid(model)
tsi <- r/(si*sqrt(1-h))
ident <- diag(n)
epsilon <- matrix(0,n,100)
e <- matrix(0,n,100)
e1 <- numeric(n)
e2 <- numeric(n)
for(i in 1:100) {
 epsilon[,i] <- rnorm(n,0,1)
 e[,i] <- (ident - H)%%epsilon[,i]
 u <- diag(ident - H)
 e[,i] <- e[,i]/sqrt(u)
 e[,i] <- sort(e[,i])
}
for(i in 1:n) {
 eo <- sort(e[i,])
 e1[i] <- eo[5]
e2[i] <- eo[95]
}
}
}

```

```

med <- apply(e,1,mean)
faixa <- range(tsi,e1,e2)
qqnorm(tsi,xlab="Theoretical Quantiles",
 ylab="Std. deviance resid.", main=main, ylim=faixa, pch=1)
 par(new=T)
 qqnorm(e1,axes=F,xlab="",ylab="",ylim=faixa,main="",type="l",lty=1)
 par(new=T)
 qqnorm(e2,axes=F,xlab="",ylab="",ylim=faixa,main="", type="l",lty=1)
 par(new=T)
 qqnorm(med,axes=F,xlab="",ylab="",ylim=faixa,main="",type="l",lty=2)
 mtext("Normal Q-Q plot", 3, 0.25)
}
else {
 ##For Poisson
 if(model$family$family=="poisson") {
 main <- "Poisson Model"
 X <- model.matrix(model)
n <- nrow(X)
 p <- ncol(X)
w <- model$weights
W <- diag(w)
H <- solve(t(X)%*%W)%*%X)
 H <- sqrt(W)%*%X)%*%H)%*%t(X)%*%sqrt(W)
 h <- diag(H)
td <- resid(model,type="deviance")/sqrt(1-h)
e <- matrix(0,n,100)
for(i in 1:100) {
nresp <- rpois(n, fitted(model))
 fit <- glm(nresp ~ X , family=poisson, maxit=1000)
 w <- fit$weights
 W <- diag(w)
H <- solve(t(X)%*%W)%*%X)
 H <- sqrt(W)%*%X)%*%H)%*%t(X)%*%sqrt(W)
 h <- diag(H)
e[,i] <- sort(resid(fit,type="deviance")/sqrt(1-h))
}
 e1 <- numeric(n)
 e2 <- numeric(n)
 for(i in 1:n) {
 eo <- sort(e[i,])
 e1[i] <- eo[5]
 }
e2[i] <- eo[95]
}
med <- apply(e,1,mean)
faixa <- range(td,e1,e2)
qqnorm(td,xlab="Theoretical Quantiles",
 ylab="Std. deviance resid.", ylim=faixa,main=main,pch=1)
 par(new=T)
 qqnorm(e1,axes=F,xlab="",ylab="",type="l",ylim=faixa,main="",lty=1)
 par(new=T)
 qqnorm(e2,axes=F,xlab="",ylab="", type="l",ylim=faixa,main="",lty=1)
 par(new=T)
 qqnorm(med,axes=F,xlab="", ylab="", type="l",ylim=faixa,main="",lty=2)
 mtext("Normal Q-Q plot", 3, 0.25)
}
else {
 ##For Binomial
 if(model$family$family=="binomial") {
 main <- "Binomial Model"
 X <- model.matrix(model)
n <- nrow(X)
 p <- ncol(X)
w <- model$weights
W <- diag(w)
H <- solve(t(X)%*%W)%*%X)
 H <- sqrt(W)%*%X)%*%H)%*%t(X)%*%sqrt(W)
 h <- diag(H)
td <- resid(model,type="deviance")/sqrt(1-h)
e <- matrix(0,n,100)
for(i in 1:100) {
dif <- runif(n) - fitted(model)
 dif[dif >= 0] <- 0
 dif[dif < 0] <- 1
nresp <- dif
 fit <- glm(nresp ~ X, family=binomial,maxit=1000)
 w <- fit$weights

```

```

 W <- diag(w)
H <- solve(t(X)%*%W%*%X)
 H <- sqrt(W)%*%X%*%H%*%t(X)%*%sqrt(W)
 h <- diag(H)
e[,i] <- sort(resid(fit,type="deviance")/sqrt(1-h))
}
 e1 <- numeric(n)
 e2 <- numeric(n)
 for(i in 1:n) {
 eo <- sort(e[i,])
 e1[i] <- eo[5]
e2[i] <- eo[95]
 }
med <- apply(e,1,mean)
faixa <- range(td,e1,e2)
qqnorm(td,xlab="Theoretical Quantiles",
 ylab="Std. deviance resid.", ylim=faixa, main=main,pch=1)
par(new=T)
qqnorm(e1,axes=F,xlab="",ylab="",type="l",ylim=faixa,main="",lty=1)
par(new=T)
qqnorm(e2,axes=F,xlab="",ylab="", type="l",ylim=faixa,main="",lty=1)
par(new=T)
qqnorm(med,axes=F,xlab="", ylab="", type="l",ylim=faixa,main="",lty=2)
mtext("Normal Q-Q plot", 3, 0.25)
}
else {
 ## For Gamma
 if(model$family$family=="Gamma") {
 main <- "Gamma Model"
 X <- model.matrix(model)
n <- nrow(X)
 p <- ncol(X)
w <- model$weights
W <- diag(w)
H <- solve(t(X)%*%W%*%X)
 H <- sqrt(W)%*%X%*%H%*%t(X)%*%sqrt(W)
h <- diag(H)
ro <- resid(model,type="response")
 fi <- (n-p)/sum((ro/(fitted(model)))^ 2)
 td <- resid(model,type="deviance")*sqrt(fi/(1-h))
e <- matrix(0,n,100)
 for(i in 1:100) {
resp <- rgamma(n,fi)
 resp <- (fitted(model)/fi)*resp
 fit <- glm(resp ~ X, family=Gamma,maxit=1000) #(link=log)
 w <- fit$weights
 W <- diag(w)
H <- solve(t(X)%*%W%*%X)
 H <- sqrt(W)%*%X%*%H%*%t(X)%*%sqrt(W)
h <- diag(H)
 ro <- resid(fit,type="response")
 phi <- (n-p)/sum((ro/(fitted(fit)))^ 2)
e[,i] <- sort(resid(fit,type="deviance")*sqrt(phi/(1-h)))
}
 e1 <- numeric(n)
 e2 <- numeric(n)
 for(i in 1:n) {
 eo <- sort(e[i,])
 e1[i] <- eo[5]
e2[i] <- eo[95]
 }
med <- apply(e,1,mean)
faixa <- range(td,e1,e2)
qqnorm(td,xlab="Theoretical Quantiles",
 ylab="Std. deviance resid.", ylim=faixa,main=main, pch=1)
par(new=T)
qqnorm(e1,axes=F,xlab="",ylab="",type="l",ylim=faixa,main="",lty=1)
par(new=T)
qqnorm(e2,axes=F,xlab="",ylab="", type="l",ylim=faixa,main="",lty=1)
par(new=T)
qqnorm(med,axes=F,xlab="", ylab="", type="l",ylim=faixa,main="",lty=2)
mtext("Normal Q-Q plot", 3, 0.25)
}
else {
 if(strsplit(model$family[[1]],split="\\(")[[1]][1]=="Negative Binomial") {
 main <- "Binomial negative Model"

```



```

```{r}
hist(dados$Valor);
4) Teste de Shapiro-Wilk (SHAPIRO; WILK, 1965):
```{r}
shapiro.test(dados$Valor)

Transformação dos dados

1) Quadrado:
```{r}
hist((dados$Valor)^2)
mquadrado<-glm((Valor)^2~Area+Indice+Metodo,data=dados)
summary(mquadrado)
diagnosticoModelo(mquadrado)

2) Log:
```{r}
hist(log(dados$Valor))
mlog<-glm(log(Valor)~Area+Indice+Metodo,data=dados)
summary(mlog)
diagnosticoModelo(mlog)

3) Normalizado:
```{r}
library(BBmisc)
hist(normalize(dados$Valor))
mnorm<-glm(normalize(Valor)~Area+Indice+Metodo,data=dados)
summary(mnorm)
diagnosticoModelo(mnorm)

# Comparação dos resíduos
```{r}
log<-mean(resid(mlog)^2)
normalizado<-mean(resid(mnorm)^2)
quadrado<-mean(resid(mquadrado)^2)
res<-data.frame(log,normalizado,quadrado)
boxplot(res)

Modelo Final

1) Análise de variância
```{r}
anova(mquadrado,test="F")

2) Contrastes
```{r, echo=FALSE}
contrasteModelo <-
coms <- function(qvar=NULL,mma=NULL,siglevel=0.05) {

 ## Create a ordered levels of desired variable
 ## levelsord <- sort(tapply(eval(mma$formula[[2]]),
 ## eval(as.name(qvar)),mean,na.rm=TRUE))
 levelsord <- sort(tapply(eval(mma$call[[2]][[2]]),
 eval(as.name(qvar)),mean,na.rm=TRUE))

 ## Starting the ordered qvar
 qvarmma <- factor(eval(as.name(qvar)),levels=names(levelsord))

 ## Starting the quartemp, at begin it is the same of qvarmma
 quartemp <- qvarmma

```



```

cat("-----\n")
 qvarmma <- qvartemp
 quartemp <- qvarmma
cont <- cont-1
 }
 }
 cont <- cont+1
 }
 cat("\n")
 cat("----- Final result of the analysis of contrast -----\n")
 cat("| ")
 cat(paste(levels(qvarmma),"|"))
 cat("\n")
 cat("-----\n")
 cat("Mean by factor levels considering the analysis of contrast\n")
 print(sort(tapply(eval(mma$call[[2]][[2]]),qvarmma,mean,na.rm=TRUE)))
}
...

```{r}
attach(dados)
contrasteModelo(qvar="Indice",mma=mquadrado)
detach(dados)
...

```{r}
attach(dados)
contrasteModelo(qvar="Area",mma=mquadrado)
detach(dados)
...

3) Gráfico

```{r, fig.width=10}
library(ggplot2)
valor<-(dados$Valor)^2
ggplot(dados, aes(x=as.factor(Area), y=valor)) +
  geom_jitter(position=position_jitter(width=0.3, height=0.2),
  aes(colour=as.factor(Indice)), alpha=0.9) +
  geom_boxplot(aes(color=as.factor(Indice),fill=Indice),
  alpha = 0.5, show.legend = FALSE) +
  labs(x="Área", y="Valor",color="Indice")
...

4) Gráfico de significância

```{r}
dados2<-dados
levels(dados2$Indice)
dados2$Indice<-as.character(dados2$Indice)
dados2$Indice[dados2$Indice == "CONFORME RESULTADOS"]<-"CONFORME RESULTADOS"
...

```{r}
dados3<-dados2
levels(dados3$Area)
dados3$Area<-as.character(dados2$Area)
dados3$Area[dados3$Area == "CONFORME RESULTADOS"]<-"CONFORME RESULTADOS"
...

```{r, fig.width=10}
library(ggplot2)
valor<-(dados$Valor)^2
ggplot(dados3, aes(x=as.factor(Area), y=valor)) +
 geom_jitter(position=position_jitter(width=0.3, height=0.2),
 aes(colour=as.factor(Indice)), alpha=0.9) +
 geom_boxplot(aes(color=as.factor(Indice),fill=Indice),
 alpha = 0.5, show.legend = FALSE) +
 labs(x="Área", y="Valor",color="Indice")
...

```

## APÊNDICE B.2 - ANÁLISES DOS DADOS ORBITAIS E AEROTRANSPORTADOS COM NDVI

### # Análises

1) Descritiva básica:

```
summary(dados)
Metodo Area Indice Valor
Aerotransportado:216 Agricultura :192 GLI :302 Min. :-0.31451
Orbital :920 Campo :184 NDVI :230 1st Qu. :-0.01186
Floresta_Nativa :196 NGRDI :302 Median : 0.16328
Floresta_Plantada:192 VARI :302 Mean : 0.18813
Pastagem_Nativa :180 Max. : 0.30483
Pastagem_Plantada:192 Max. : 0.92356
```

2) Descritiva com o pacote mosaic:

```
mean(Valor ~Area+Metodo,data=dados)
Agricultura.Aerotransportado Campo.Aerotransportado
0.004332101 0.076133572
Floresta_Nativa.Aerotransportado Floresta_Plantada.Aerotransportado
0.152118653 0.133304757
Pastagem_Nativa.Aerotransportado Pastagem_Plantada.Aerotransportado
0.071311265 0.049938016
Agricultura.Orbital Campo.Orbital
0.035322258 0.161007817
Floresta_Nativa.Orbital Floresta_Plantada.Orbital
0.360056324 0.397654025
Pastagem_Nativa.Orbital Pastagem_Plantada.Orbital
0.198611403 0.119229285

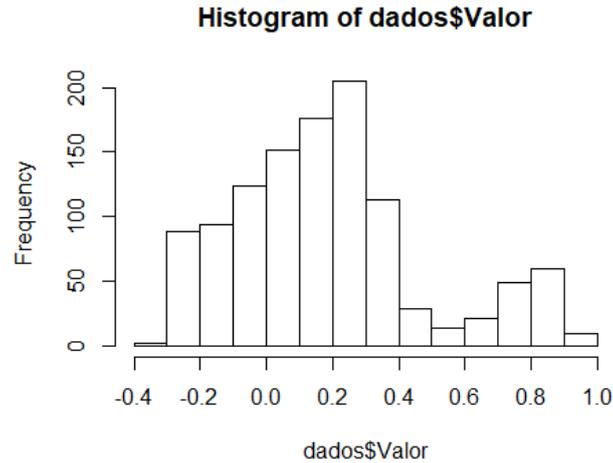
mean(Valor ~Indice+Metodo,data=dados)
GLI.Aerotransportado NDVI.Aerotransportado NGRDI.Aerotransportado
0.19152150 NaN 0.02475331
VARI.Aerotransportado GLI.Orbital NDVI.Orbital
0.02729438 0.15708071 0.61747700
NGRDI.Orbital VARI.Orbital

mean(Valor ~Area+Indice+Metodo,data=dados)
Agricultura.GLI.Aerotransportado Agricultura.VARI.Aerotransportado
0.128564754 -0.065920269
Campo.GLI.Aerotransportado Campo.VARI.Aerotransportado
0.196604842 -0.004466500
Floresta_Nativa.GLI.Aerotransportado Floresta_Nativa.VARI.Aerotransportado
0.233750303 0.124786756
Floresta_Plantada.GLI.Aerotransportado Floresta_Plantada.VARI.Aerotransportado
0.247668485 0.083246677
Pastagem_Nativa.GLI.Aerotransportado Pastagem_Nativa.VARI.Aerotransportado
0.175620489 0.019209983
Pastagem_Plantada.GLI.Aerotransportado Pastagem_Plantada.VARI.Aerotransportado
0.166920105 -0.012639558
Agricultura.NDVI.Aerotransportado Agricultura.GLI.Orbital
NaN 0.031902823
Campo.NDVI.Aerotransportado Campo.GLI.Orbital
NaN 0.109077209
Floresta_Nativa.NDVI.Aerotransportado Floresta_Nativa.GLI.Orbital
NaN 0.261397244
Floresta_Plantada.NDVI.Aerotransportado Floresta_Plantada.GLI.Orbital
NaN 0.296713571
Pastagem_Nativa.NDVI.Aerotransportado Pastagem_Nativa.GLI.Orbital
NaN 0.136097488
Pastagem_Plantada.NDVI.Aerotransportado Pastagem_Plantada.GLI.Orbital
NaN 0.100545303
Agricultura.NGRDI.Aerotransportado Agricultura.NDVI.Orbital
-0.049648181 0.372333591
Campo.NGRDI.Aerotransportado Campo.NDVI.Orbital
0.016713205 0.576059770
Floresta_Nativa.NGRDI.Aerotransportado Floresta_Nativa.NDVI.Orbital
0.097818901 0.793933277
Floresta_Plantada.NGRDI.Aerotransportado Floresta_Plantada.NDVI.Orbital
0.068999107 0.856902253
Pastagem_Nativa.NGRDI.Aerotransportado Pastagem_Nativa.NDVI.Orbital
0.019103322 0.634403517
Pastagem_Plantada.NGRDI.Aerotransportado Pastagem_Plantada.NDVI.Orbital
0.015082670 0.465883127
Floresta_Nativa.VARI.Aerotransportado Agricultura.NGRDI.Orbital
0.124786756 -0.114123968
Campo.NGRDI.Orbital Agricultura.VARI.Orbital
-0.019416589 -0.148823412
Floresta_Nativa.NGRDI.Orbital Campo.VARI.Orbital
```

```
0.161898740 -0.021689124
Floresta_Plantada.NGRDI.Orbital Floresta_Nativa.VARI.Orbital
0.187519500 0.222996036
Pastagem_Nativa.NGRDI.Orbital Floresta_Plantada.VARI.Orbital
0.008035231 0.249480775
Pastagem_Plantada.NGRDI.Orbital Pastagem_Nativa.VARI.Orbital
-0.039833972 0.015909378
Pastagem_Plantada.VARI.Orbital
-0.049677319
```

3) Histograma:

```
hist(dados$Valor);
```



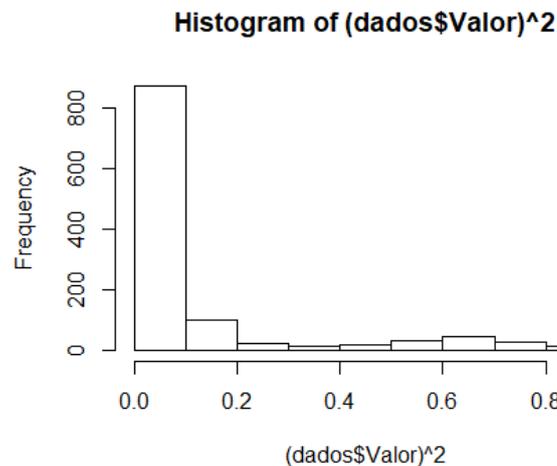
4) Teste de Shapiro-wilk (SHAPIRO; WILK, 1965):

```
shapiro.test(dados$Valor)
##
Shapiro-wilk normality test
##
data: dados$Valor
W = 0.9385, p-value < 2.2e-16
```

# Transformação dos dados

1) Quadrado:

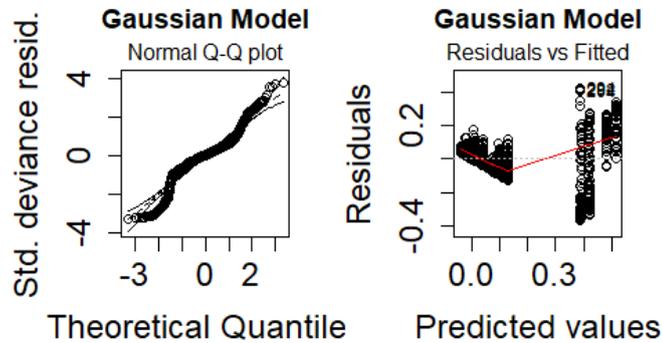
```
hist((dados$Valor)^2)
```



```
mquadrado<-glm((Valor)^2~Area+Indice+Metodo,data=dados)
summary(mquadrado)
```

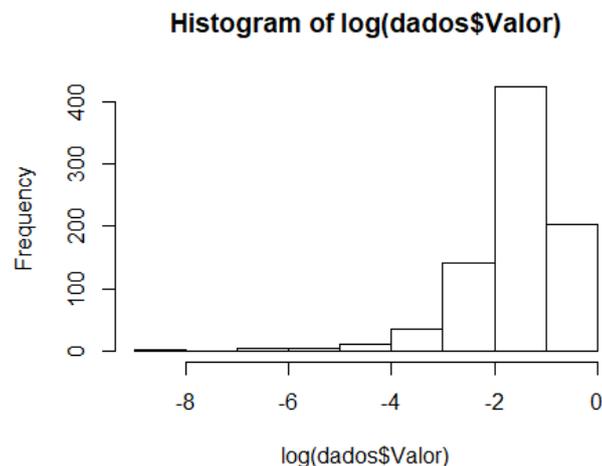
```
Call:
glm(formula = (Valor)^2 ~ Area + Indice + Metodo, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-0.37038 -0.03914 0.00015 0.04776 0.42856
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.021227 0.012178 -1.743 0.08159 .
AreaCampo 0.033201 0.011876 2.796 0.00527 **
AreaFloresta_Nativa 0.094213 0.011689 8.060 1.94e-15 ***
AreaFloresta_Plantada 0.125496 0.011749 10.681 < 2e-16 ***
AreaPastagem_Nativa 0.030063 0.011944 2.517 0.01197 *
AreaPastagem_Plantada 0.003842 0.011749 0.327 0.74373
IndiceNDVI 0.386374 0.010299 37.514 < 2e-16 ***
IndiceNGRDI -0.018599 0.009368 -1.985 0.04734 *
IndiceVARI 0.003776 0.009368 0.403 0.68700
MetodoOrbital 0.023568 0.008976 2.626 0.00877 **

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.01325209)
##
Null deviance: 46.511 on 1135 degrees of freedom
Residual deviance: 14.922 on 1126 degrees of freedom
AIC: -1675.8
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mquadrado)
```



2) Log:

```
hist(log(dados$Valor))
Warning in log(dados$Valor): NaNs produzidos
```

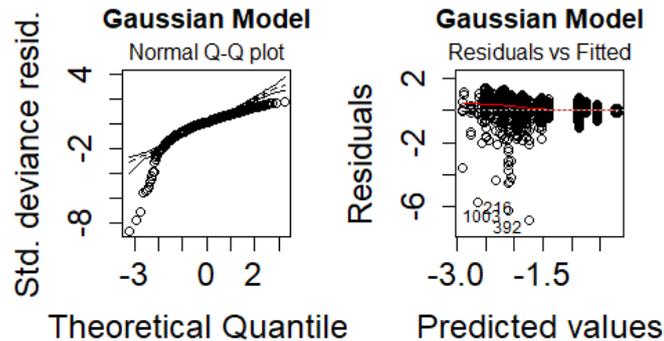


```

mlog<-glm(log(Valor)~Area+Indice+Metodo,data=dados)
Warning in log(Valor): NaNs produzidos
summary(mlog)
Call:
glm(formula = log(Valor) ~ Area + Indice + Metodo, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-6.8512 -0.2619 0.0934 0.4822 1.4285
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -2.49962 0.11330 -22.061 < 2e-16 ***
AreaCampo 0.32578 0.11888 2.740 0.00627 **
AreaFloresta_Nativa 0.62224 0.10887 5.716 1.53e-08 ***
AreaFloresta_Plantada 0.67184 0.10936 6.143 1.26e-09 ***
AreaPastagem_Nativa 0.11534 0.11599 0.994 0.32032
AreaPastagem_Plantada -0.03209 0.11883 -0.270 0.78719
IndiceNDVI 1.19818 0.07987 15.002 < 2e-16 ***
IndiceNGRDI -0.38342 0.08247 -4.649 3.89e-06 ***
IndiceVARI -0.12119 0.08247 -1.469 0.14209
MetodoOrbital 0.42965 0.07677 5.596 2.99e-08 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.6866944)
##
Null deviance: 970.45 on 826 degrees of freedom
Residual deviance: 561.03 on 817 degrees of freedom
(309 observations deleted due to missingness)
AIC: 2048
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mlog)

```



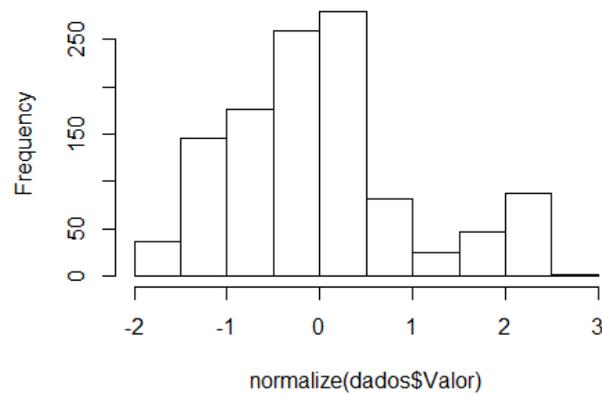
### 3) Normalizado:

```

library(BBmisc)
Warning: package 'BBmisc' was built under R version 3.5.3
##
Attaching package: 'BBmisc'
The following objects are masked from 'package:dplyr':
##
coalesce, collapse
The following object is masked from 'package:base':
##
isFALSE
hist(normalize(dados$Valor))

```

Histogram of normalize(dados\$Valor)

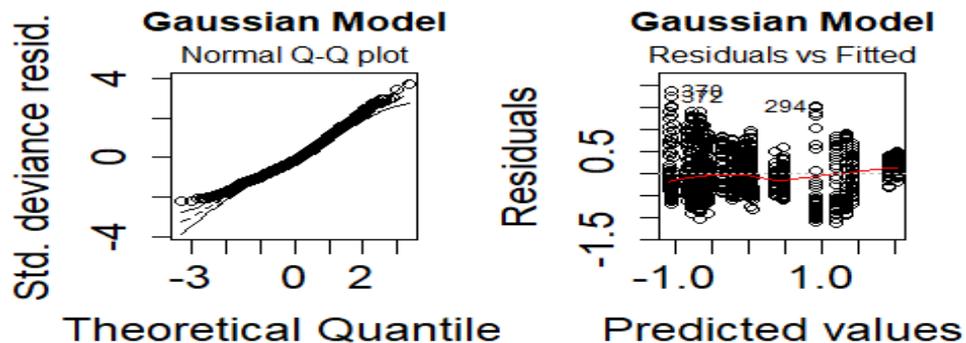


```

mnorm<-glm(normalize(Valor)~Area+Indice+Metodo,data=dados)
summary(mnorm)
Call:
glm(formula = normalize(Valor) ~ Area + Indice + Metodo, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-1.12912 -0.35183 -0.07359 0.32292 1.88367
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.61317 0.05420 -11.313 < 2e-16 ***
AreaCampo 0.39754 0.05286 7.521 1.11e-13 ***
AreaFloresta_Nativa 1.00055 0.05202 19.233 < 2e-16 ***
AreaFloresta_Plantada 1.09218 0.05229 20.886 < 2e-16 ***
AreaPastagem_Nativa 0.49805 0.05316 9.369 < 2e-16 ***
AreaPastagem_Plantada 0.26304 0.05229 5.030 5.70e-07 ***
IndiceNDVI 1.55243 0.04584 33.867 < 2e-16 ***
IndiceNGRDI -0.46294 0.04169 -11.103 < 2e-16 ***
IndiceVARI -0.42314 0.04169 -10.149 < 2e-16 ***
MetodoOrbital -0.01305 0.03995 -0.327 0.744

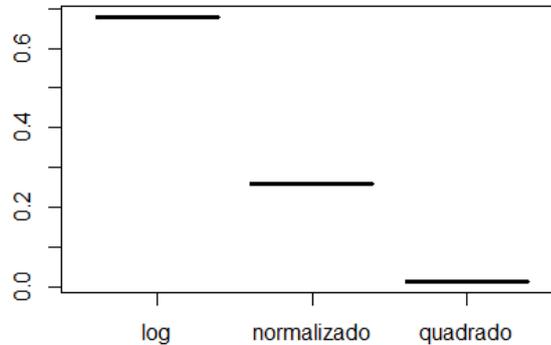
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.262499)
##
Null deviance: 1135.00 on 1135 degrees of freedom
Residual deviance: 295.57 on 1126 degrees of freedom
AIC: 1716.4
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mnorm)

```



### # Comparação dos resíduos

```
log<-mean(resid(mlog)^2)
normalizado<-mean(resid(mnorm)^2)
quadrado<-mean(resid(mquadrado)^2)
res<-data.frame(log,normalizado,quadrado)
boxplot(res)
```



### # Modelo Final

#### 1) Análise de variância

```
anova(mquadrado,test="F")
Analysis of Deviance Table
##
Model: gaussian, link: identity
##
Response: (valor)^2
##
Terms added sequentially (first to last)
##
##
Df Deviance Resid. Df Resid. Dev F Pr(>F)
NULL 5 2.5109 1135 46.511
Area 3 28.9873 1127 15.013 729.1252 < 2.2e-16 ***
Indice 1 0.0914 1126 14.922 6.8937 0.008767 **

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

#### 2) Contrastes

```
attach(dados)
contrasteModelo(qvar="Indice",mma=mquadrado)

--- Starting the contrast analysis at 5 % ---

Actual levels in increasing order mean:
| NGRDI | GLI | VARI | NDVI |
##
Result of contrast: NGRDI versus GLI
##
NGRDI and GLI are different

Actual levels in increasing order mean:
| NGRDI | GLI | VARI | NDVI |
##
Result of contrast: GLI versus VARI
##
GLI and VARI are not different

Actual levels in increasing order mean:
| NGRDI | GLI | VARI | NDVI |
##
Result of contrast: GLI versus NDVI
##
GLI and NDVI are different

----- Final result of the analysis of contrast -----
| NGRDI | GLI | VARI | NDVI |

```

```

Mean by factor levels considering the analysis of contrast
NGRDI GLIVARI NDVI
0.02635187 0.04683915 0.43707791
detach(dados)

attach(dados)
contrasteModelo(qvar="Area",mma=mquadrado)

--- Starting the contrast analysis at 5 % ---

Actual levels in increasing order mean:
| Agricultura | Pastagem_Plantada | Pastagem_Nativa | Campo | Floresta_Nativa |
Floresta_Plantada |
##
Result of contrast: Agricultura versus Pastagem_Plantada
##
Agricultura and Pastagem_Plantada are not different

Actual levels in increasing order mean:
| AgriculturaPastagem_Plantada | Pastagem_Nativa | Campo | Floresta_Nativa |
Floresta_Plantada |
##
Result of contrast: AgriculturaPastagem_Plantada versus Pastagem_Nativa
##
AgriculturaPastagem_Plantada and Pastagem_Nativa are different

Actual levels in increasing order mean:
| AgriculturaPastagem_Plantada | Pastagem_Nativa | Campo | Floresta_Nativa |
Floresta_Plantada |
##
Result of contrast: Pastagem_Nativa versus Campo
##
Pastagem_Nativa and Campo are not different

Actual levels in increasing order mean:
| AgriculturaPastagem_Plantada | Pastagem_NativaCampo | Floresta_Nativa | Floresta_Plantada
|
##
Result of contrast: Pastagem_NativaCampo versus Floresta_Nativa
##
Pastagem_NativaCampo and Floresta_Nativa are different

Actual levels in increasing order mean:
| AgriculturaPastagem_Plantada | Pastagem_NativaCampo | Floresta_Nativa | Floresta_Plantada
|
##
Result of contrast: Floresta_Nativa versus Floresta_Plantada
##
Floresta_Nativa and Floresta_Plantada are not different

----- Final result of the analysis of contrast -----
| AgriculturaPastagem_Plantada | Pastagem_NativaCampo | Floresta_NativaFloresta_Plantada |

Mean by factor levels considering the analysis of contrast
AgriculturaPastagem_Plantada Pastagem_NativaCampo
0.07438776 0.10286529
Floresta_NativaFloresta_Plantada
0.18239475
detach(dados)

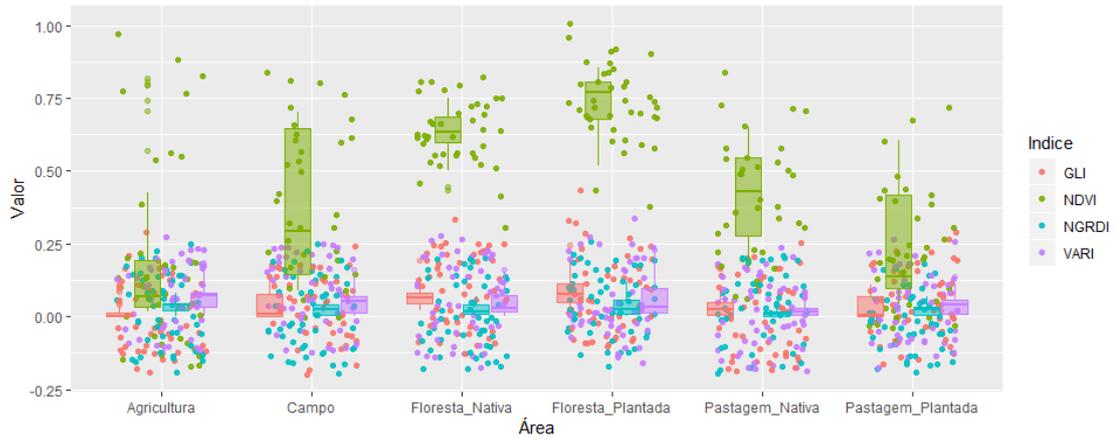
```

### 3) Gráfico

```

library(ggplot2)
valor<-(dados$Valor)^2
ggplot(dados, aes(x=as.factor(Area), y=valor)) +
geom_jitter(position=position_jitter(width=0.3, height=0.2),
aes(colour=factor(Indice)), alpha=0.9) +
geom_boxplot(aes(color=as.factor(Indice),fill=Indice),
alpha =0.5, show.legend =FALSE) +
labs(x="Área", y="Valor",color="Indice")

```



#### 4) gráfico de significância

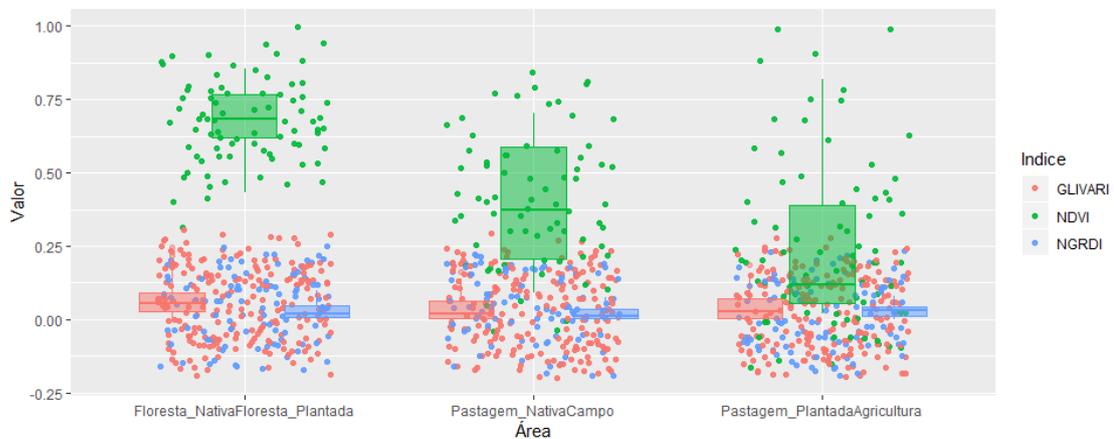
```

dados2<-dados
levels(dados2$Indice)
[1] "GLI" "NDVI" "NGRDI" "VARI"
dados2$Indice<-as.character(dados2$Indice)
dados2$Indice[dados2$Indice == "GLI"]<-"GLIVARI"
dados2$Indice[dados2$Indice == "NDVI"]<-"NDVDI"
dados2$Indice[dados2$Indice == "NGRDI"]<-"NGRDI"
dados2$Indice[dados2$Indice == "VARI"]<-"GLIVARI"
dados3<-dados2

levels(dados3$Area)
[1] "Agricultura" "Campo" "Floresta_Nativa"
[4] "Floresta_Plantada" "Pastagem_Nativa" "Pastagem_Plantada"
dados3$Area<-as.character(dados2$Area)
dados3$Area[dados3$Area == "Agricultura"]<-"Pastagem_PlantadaAgricultura"
dados3$Area[dados3$Area == "Campo"]<-"Pastagem_NativaCampo"
dados3$Area[dados3$Area == "Floresta_Nativa"]<-"Floresta_NativaFloresta_Plantada"
dados3$Area[dados3$Area == "Floresta_Plantada"]<-"Floresta_NativaFloresta_Plantada"
dados3$Area[dados3$Area == "Pastagem_Nativa"]<-"Pastagem_NativaCampo"
dados3$Area[dados3$Area == "Pastagem_Plantada"]<-"Pastagem_PlantadaAgricultura"

library(ggplot2)
valor<-(dados$valor)^2
ggplot(dados3, aes(x=as.factor(Area), y=valor)) +
 geom_jitter(position=position_jitter(width=0.3, height=0.2),
 aes(colour=factor(Indice)), alpha=0.9) +
 geom_boxplot(aes(color=as.factor(Indice), fill=Indice),
 alpha=0.5, show.legend =FALSE) +
 labs(x="Area", y="valor", color="Indice")

```



## APÊNDICE B.3 - ANÁLISES DOS DADOS ORBITAIS E AEROTRANSPORTADOS

### # Análises

1) Descritiva básica:

```
summary(dados)
Metodo Area Indice Valor
Aerotransportado:216 Agricultura :153 GLI :302 Min. : -0.31451
Orbital :690 Campo :147 NGRDI:302 1st Qu.: -0.04878
Floresta_Nativa :156 VARI :302 Median : 0.09619
Floresta_Plantada:153 Mean : 0.07914
Pastagem_Nativa :144 3rd Qu.: 0.23150
Pastagem_Plantada:153 Max. : 0.49467
```

2) Descritiva com o pacote mosaic:

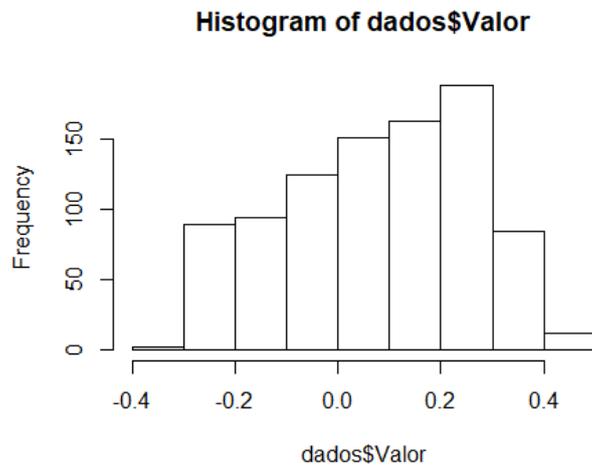
```
mean(Valor ~Area+Metodo,data=dados)
Agricultura.Aerotransportado Campo.Aerotransportado
0.004332101 0.076133572
Floresta_Nativa.Aerotransportado Floresta_Plantada.Aerotransportado
0.152118653 0.133304757
Pastagem_Nativa.Aerotransportado Pastagem_Plantada.Aerotransportado
0.071311265 0.049938016
Agricultura.Orbital Campo.Orbital
-0.077014853 0.022657165
Floresta_Nativa.Orbital Floresta_Plantada.Orbital
0.215430673 0.244571282
Pastagem_Nativa.Orbital Pastagem_Plantada.Orbital
0.053347366 0.003678004
```

```
mean(Valor ~Indice+Metodo,data=dados)
GLI.Aerotransportado NGRDI.Aerotransportado VARI.Aerotransportado
0.19152150 0.02475331 0.02729438
GLI.Orbital NGRDI.Orbital VARI.Orbital
0.15708071 0.03198133 0.04642741
```

```
mean(Valor ~Area+Indice+Metodo,data=dados)
Agricultura.GLI.Aerotransportado Agricultura.NGRDI.Aerotransportado
0.128564754 -0.049648181
Campo.GLI.Aerotransportado Campo.NGRDI.Aerotransportado
0.196604842 0.016713205
Floresta_Nativa.GLI.Aerotransportado Floresta_Nativa.NGRDI.Aerotransportado
0.233750303 0.097818901
Floresta_Plantada.GLI.Aerotransportado Floresta_Plantada.NGRDI.Aerotransportado
0.247668485 0.068999107
Pastagem_Nativa.GLI.Aerotransportado Pastagem_Nativa.NGRDI.Aerotransportado
0.175620489 0.019103322
Pastagem_Plantada.GLI.Aerotransportado Pastagem_Plantada.NGRDI.Aerotransportado
0.166920105 -0.004466500
Agricultura.VARI.Aerotransportado Agricultura.GLI.Orbital
-0.065920269 0.031902823
Campo.VARI.Aerotransportado Campo.GLI.Orbital
0.015082670 0.109077209
Floresta_Nativa.VARI.Aerotransportado Floresta_Nativa.GLI.Orbital
0.124786756 0.261397244
Floresta_Plantada.VARI.Aerotransportado Floresta_Plantada.GLI.Orbital
0.083246677 0.296713571
Pastagem_Nativa.VARI.Aerotransportado Pastagem_Nativa.GLI.Orbital
0.019209983 0.136097488
Pastagem_Plantada.VARI.Aerotransportado Pastagem_Plantada.GLI.Orbital
-0.012639558 0.100545303
Agricultura.NGRDI.Orbital Agricultura.VARI.Orbital
-0.114123968 -0.148823412
Campo.NGRDI.Orbital Campo.VARI.Orbital
-0.019416589 -0.021689124
Floresta_Nativa.NGRDI.Orbital Floresta_Nativa.VARI.Orbital
0.161898740 0.222996036
Floresta_Plantada.NGRDI.Orbital Floresta_Plantada.VARI.Orbital
0.187519500 0.249480775
Pastagem_Nativa.NGRDI.Orbital Pastagem_Nativa.VARI.Orbital
0.008035231 0.015909378
Pastagem_Plantada.NGRDI.Orbital Pastagem_Plantada.VARI.Orbital
-0.039833972 -0.049677319
```

3) Histograma:

```
hist (dados$Valor);
```



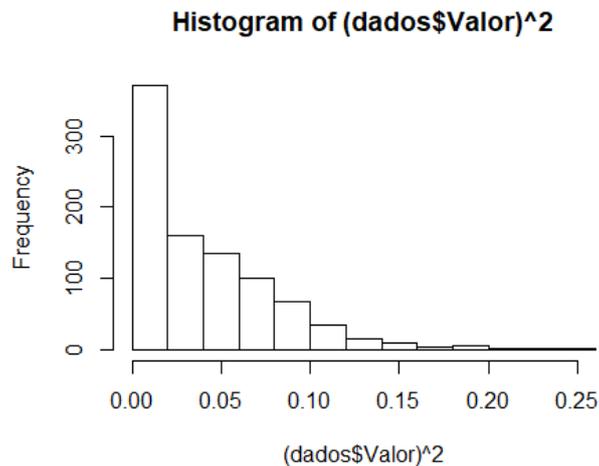
4) Teste de Shapiro-wilk (SHAPIRO; WILK, 1965):

```
shapiro.test(dados$Valor)
##
Shapiro-wilk normality test
##
data: dados$Valor
w = 0.96862, p-value = 4.629e-13
```

# Transformação dos dados

1) Quadrado:

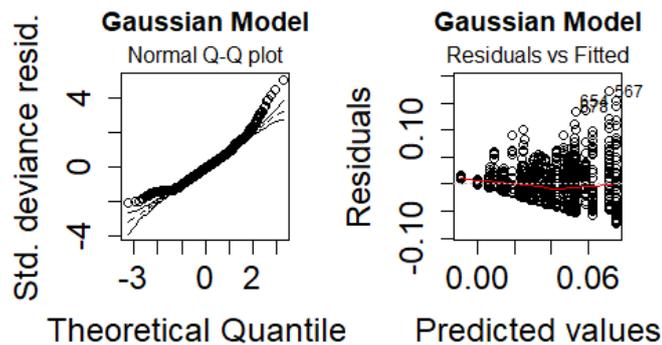
```
hist((dados$Valor)^2)
```



```
mquadrado<-glm((valor)^2~Area+Indice+Metodo, data=dados)
summary(mquadrado)
##
Call:
glm(formula = (valor)^2 ~ Area + Indice + Metodo, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-0.073415 -0.024778 -0.002723 0.019627 0.173592
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 0.0253417 0.0039078 6.485 1.46e-10 ***
AreaCampo -0.0006164 0.0040697 -0.151 0.8797
AreaFloresta_Nativa 0.0090419 0.0040093 2.255 0.0244 *
```

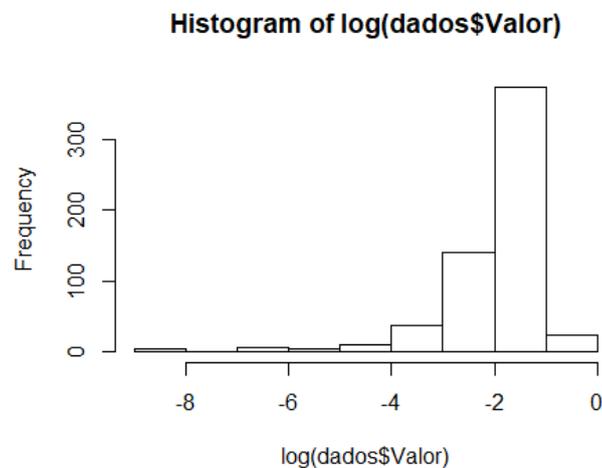
```
AreaFloresta_Plantada 0.0219114 0.0040287 5.439 6.92e-08 ***
AreaPastagem_Nativa -0.0162832 0.0040914 -3.980 7.45e-05 ***
AreaPastagem_Plantada -0.0066503 0.0040287 -1.651 0.0991 .
IndiceNGRDI -0.0185994 0.0028675 -6.486 1.45e-10 ***
IndiceVARI 0.0037757 0.0028675 1.317 0.1883
MetodoOrbital 0.0238496 0.0027476 8.680 < 2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.001241625)
##
Null deviance: 1.4255 on 905 degrees of freedom
Residual deviance: 1.1137 on 897 degrees of freedom
AIC: -3480.3
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mquadrado)
```



2) Log:

```
hist(log(dados$Valor))
Warning in log(dados$Valor): NaNs produzidos
```

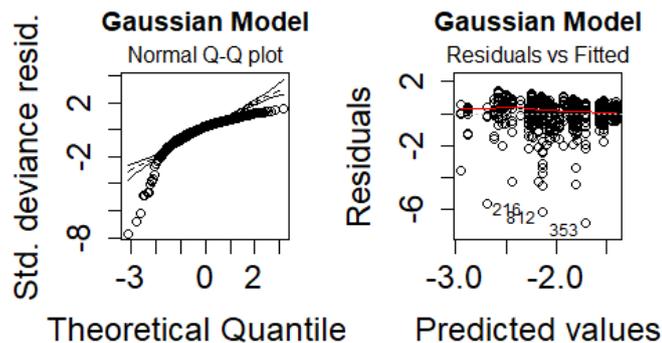


```

mlog<-glm(log(Valor)~Area+Indice+Metodo,data=dados)
Warning in log(Valor): NaNs produzidos
summary(mlog)
##
Call:
glm(formula = log(Valor) ~ Area + Indice + Metodo, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-6.8874 -0.2844 0.2083 0.5615 1.4689
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -2.24096 0.15342 -14.607 < 2e-16 ***
AreaCampo 0.09251 0.17488 0.529 0.5970
AreaFloresta_Nativa 0.35087 0.15766 2.226 0.0264 *
AreaFloresta_Plantada 0.39349 0.15826 2.486 0.0132 *
AreaPastagem_Nativa -0.26033 0.16878 -1.542 0.1235
AreaPastagem_Plantada -0.33124 0.17584 -1.884 0.0601 .
IndiceGRDI -0.38339 0.09399 -4.079 5.15e-05 ***
IndiceVARI -0.12116 0.09399 -1.289 0.1979
MetodoOrbital 0.44051 0.08744 5.038 6.27e-07 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.8877252)
##
Null deviance: 605.77 on 596 degrees of freedom
Residual deviance: 521.98 on 588 degrees of freedom
(309 observations deleted due to missingness)
AIC: 1634
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mlog)

```



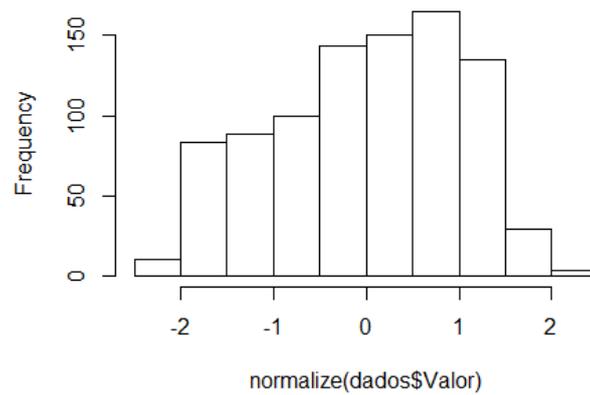
3) Normalizado:

```

library(BBmisc)
Warning: package 'BBmisc' was built under R version 3.5.3
##
Attaching package: 'BBmisc'
The following objects are masked from 'package:dplyr':
##
coalesce, collapse
The following object is masked from 'package:base':
##
isFALSE
hist(normalize(dados$Valor))

```

Histogram of normalize(dados\$Valor)

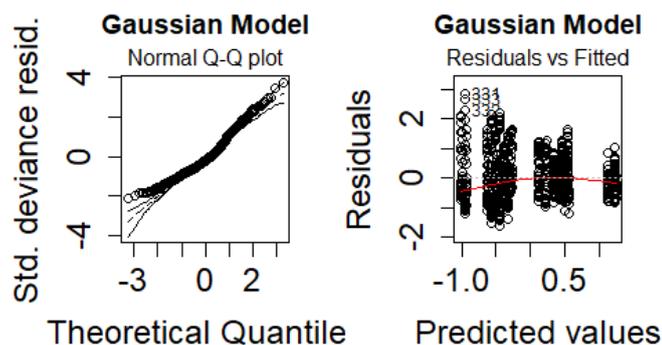


```

mnorm<-glm(normalize(Valor)~Area+Indice+Metodo,data=dados)
summary(mnorm)
##
Call:
glm(formula = normalize(Valor) ~ Area + Indice + Metodo, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-1.6159 -0.5522 -0.1394 0.4464 2.8701
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.26063 0.08562 -3.044 0.0024 **
AreaCampo 0.50918 0.08916 5.711 1.53e-08 ***
AreaFloresta_Nativa 1.40753 0.08784 16.024 < 2e-16 ***
AreaFloresta_Plantada 1.50303 0.08826 17.029 < 2e-16 ***
AreaPastagem_Nativa 0.62923 0.08964 7.020 4.38e-12 ***
AreaPastagem_Plantada 0.39410 0.08826 4.465 9.03e-06 ***
IndiceNGRDI -0.73466 0.06282 -11.694 < 2e-16 ***
IndiceVARI -0.67150 0.06282 -10.689 < 2e-16 ***
MetodoOrbital -0.02102 0.06020 -0.349 0.7271

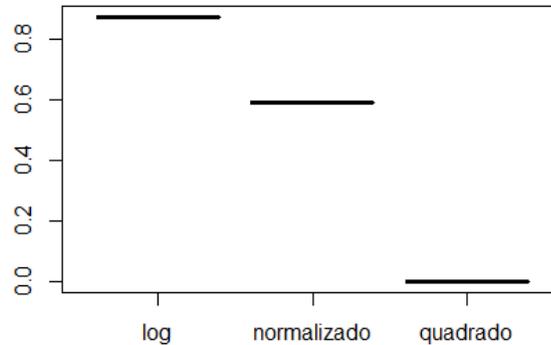
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.5959773)
##
Null deviance: 905.00 on 905 degrees of freedom
Residual deviance: 534.59 on 897 degrees of freedom
AIC: 2113.2
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mnorm)

```



### # Comparação dos resíduos

```
log<-mean(resid(mlog)^2)
normalizado<-mean(resid(mnorm)^2)
quadrado<-mean(resid(mquadrado)^2)
res<-data.frame(log,normalizado,quadrado)
boxplot(res)
```



### # Modelo Final

#### 1) Análise de variância

```
anova(mquadrado,test="F")
Analysis of Deviance Table
##
Model: gaussian, link: identity
##
Response: (valor)^2
##
Terms added sequentially (first to last)
##
##
Df Deviance Resid. Df Resid. Dev F Pr(>F)
NULL 0 905 1.4255
Area 5 0.131527 900 1.2939 21.186 < 2.2e-16 ***
Indíce 2 0.086658 898 1.2073 34.897 2.542e-15 ***
Metodo 1 0.093548 897 1.1137 75.343 < 2.2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

#### 2) Contrastes

```
attach(dados)
contrasteModelo(qvar="Indíce",mma=mquadrado)

--- Starting the contrast analysis at 5 % ---

Actual levels in increasing order mean:
| NGRDI | GLI | VARI |
##
Result of contrast: NGRDI versus GLI
##
NGRDI and GLI are different

Actual levels in increasing order mean:
| NGRDI | GLI | VARI |
##
Result of contrast: GLI versus VARI
##
GLI and VARI are not different

----- Final result of the analysis of contrast -----
| NGRDI | GLI | VARI |

```

```

Mean by factor levels considering the analysis of contrast
NGRDI GLIVARI
0.02635187 0.04683915
detach(dados)

attach(dados)
contrasteModelo(qvar="Area",mma=mquadrado)

--- Starting the contrast analysis at 5 % ---

Actual levels in increasing order mean:
| Pastagem_Nativa | Pastagem_Plantada | Campo | Agricultura | Floresta_Nativa |
Floresta_Plantada |
##
Result of contrast: Pastagem_Nativa versus Pastagem_Plantada
##
Pastagem_Nativa and Pastagem_Plantada are different

Actual levels in increasing order mean:
| Pastagem_Nativa | Pastagem_Plantada | Campo | Agricultura | Floresta_Nativa |
Floresta_Plantada |
##
Result of contrast: Pastagem_Plantada versus Campo
##
Pastagem_Plantada and Campo are not different

Actual levels in increasing order mean:
| Pastagem_Nativa | Pastagem_PlantadaCampo | Agricultura | Floresta_Nativa |
Floresta_Plantada |
##
Result of contrast: Pastagem_PlantadaCampo versus Agricultura
##
Pastagem_PlantadaCampo and Agricultura are not different

Actual levels in increasing order mean:
| Pastagem_Nativa | Pastagem_PlantadaCampoAgricultura | Floresta_Nativa | Floresta_Plantada
##
Result of contrast: Pastagem_PlantadaCampoAgricultura versus Floresta_Nativa
##
Pastagem_PlantadaCampoAgricultura and Floresta_Nativa are different

Actual levels in increasing order mean:
Pastagem_Nativa | Pastagem_PlantadaCampoAgricultura | Floresta_Nativa | Floresta_Plantada |
##
Result of contrast: Floresta_Nativa versus Floresta_Plantada
##
Floresta_Nativa and Floresta_Plantada are different

----- Final result of the analysis of contrast -----
Pastagem_Nativa | Pastagem_PlantadaCampoAgricultura | Floresta_Nativa | Floresta_Plantada |

Mean by factor levels considering the analysis of contrast
Pastagem_Nativa Pastagem_PlantadaCampoAgricultura
0.02200443 0.03611790
Floresta_Nativa Floresta_Plantada
0.04778816 0.06054972
detach(dados)

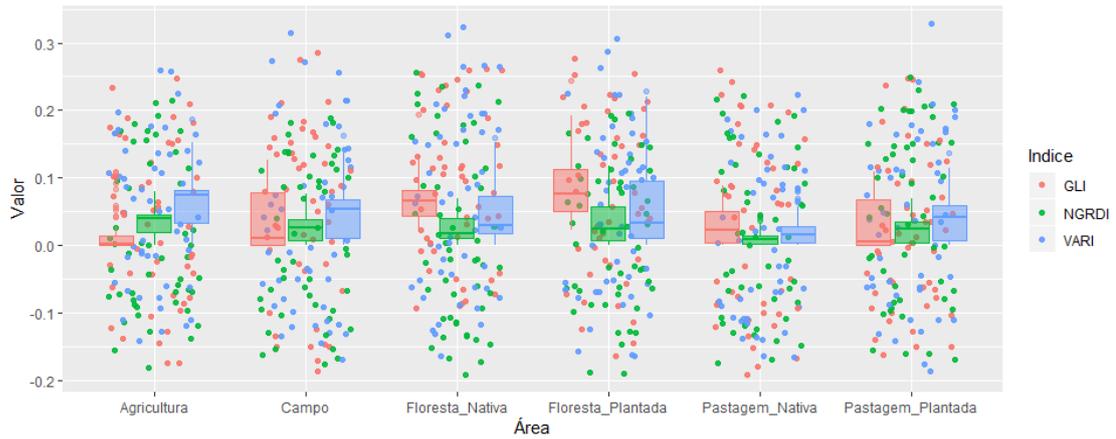
```

### 3) Gráfico

```

library(ggplot2)
valor<-(dados$Valor)^2
ggplot(dados, aes(x=as.factor(Area), y=valor)) +
geom_jitter(position=position_jitter(width=0.3, height=0.2),
aes(colour=factor(Indice)), alpha=0.9) +
geom_boxplot(aes(color=as.factor(Indice),fill=Indice),
alpha =0.5, show.legend =FALSE) +
labs(x="Área", y="Valor",color="Indice")

```



#### 4) gráfico de significância

```

dados2<-dados
levels(dados2$Indice)
[1] "GLI" "NGRDI" "VARI"
dados2$Indice<-as.character(dados2$Indice)
dados2$Indice[dados2$Indice == "GLI"]<-"GLIVARI"
dados2$Indice[dados2$Indice == "NGRDI"]<-"NGRDI"
dados2$Indice[dados2$Indice == "VARI"]<-"GLIVARI"
dados3<-dados2

levels(dados3$Area)
[1] "Agricultura" "Campo" "Floresta_Nativa"
[4] "Floresta_Plantada" "Pastagem_Nativa" "Pastagem_Plantada"
dados3$Area<-as.character(dados2$Area)
dados3$Area[dados3$Area == "Agricultura"]<-"Pastagem_PlantadaCampoAgricultura"
dados3$Area[dados3$Area == "Campo"]<-"Pastagem_PlantadaCampoAgricultura"
dados3$Area[dados3$Area == "Floresta_Nativa"]<-"Floresta_Nativa"
dados3$Area[dados3$Area == "Floresta_Plantada"]<-"Floresta_Plantada"
dados3$Area[dados3$Area == "Pastagem_Nativa"]<-"Pastagem_Nativa"
dados3$Area[dados3$Area == "Pastagem_Plantada"]<-"Pastagem_PlantadaCampoAgricultura"

library(ggplot2)
valor<-(dados$Valor)^2
ggplot(dados3, aes(x=as.factor(Area), y=valor)) +
 geom_jitter(position=position_jitter(width=0.3, height=0.2),
 aes(colour=factor(Indice)), alpha=0.9) +
 geom_boxplot(aes(color=as.factor(Indice),fill=Indice),
 alpha =0.5, show.legend =FALSE) +
 labs(x="Área", y="Valor",color="Indice")

```



## APÊNDICE B.4 - ANÁLISES DOS DADOS ORBITAIS

### # Análises

1) Descritiva básica:

```
summary(dados)
Area Indice Valor
Agricultura :117 GLI :230 Min. :-0.31451
Campo :111 NGRDI:230 1st Qu. :-0.09417
Floresta_Nativa :120 VARI :230 Median : 0.11434
Floresta_Plantada:117 Mean : 0.07850
Pastagem_Nativa :108 3rd Qu. : 0.24743
Pastagem_Plantada:117 Max. : 0.49467
```

2) Descritiva com o pacote mosaic:

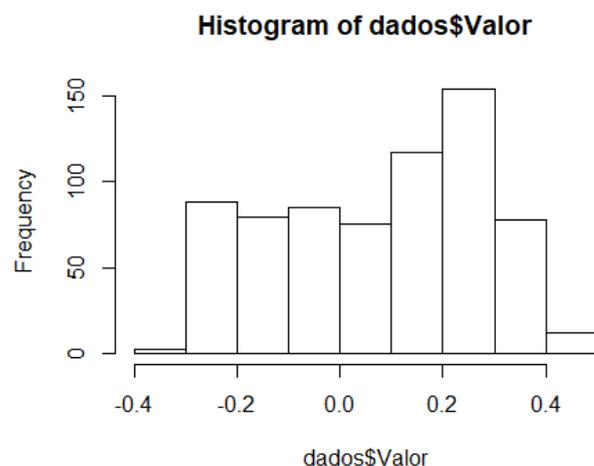
```
mean(Valor ~Area,data=dados)
Agricultura Campo Floresta_Nativa Floresta_Plantada
-0.077014853 0.022657165 0.215430673 0.244571282
Pastagem_Nativa Pastagem_Plantada
0.053347366 0.003678004
```

```
mean(Valor ~Indice,data=dados)
GLI NGRDI VARI
0.15708071 0.03198133 0.04642741
```

```
mean(Valor ~Area+Indice,data=dados)
Agricultura.GLI Campo.GLI Floresta_Nativa.GLI
0.031902823 0.109077209 0.261397244
Floresta_Plantada.GLI Pastagem_Nativa.GLI Pastagem_Plantada.GLI
0.296713571 0.136097488 0.100545303
Agricultura.NGRDI Campo.NGRDI Floresta_Nativa.NGRDI
-0.114123968 -0.019416589 0.161898740
Floresta_Plantada.NGRDI Pastagem_Nativa.NGRDI Pastagem_Plantada.NGRDI
0.187519500 0.008035231 -0.039833972
Agricultura.VARI Campo.VARI Floresta_Nativa.VARI
-0.148823412 -0.021689124 0.222996036
Floresta_Plantada.VARI Pastagem_Nativa.VARI Pastagem_Plantada.VARI
0.249480775 0.015909378 -0.049677319
```

3) Histograma:

```
hist (dados$Valor);
```

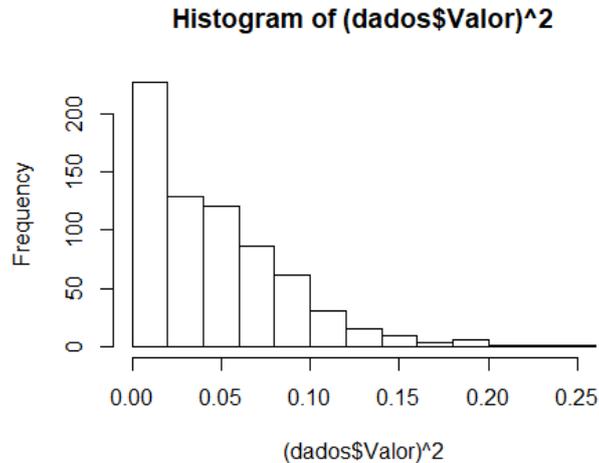


4) Teste de Shapiro-wilk (SHAPIRO; WILK, 1965):

```
shapiro.test(dados$Valor)
##
Shapiro-wilk normality test
##
data: dados$valor
W = 0.94985, p-value = 1.492e-14
```

## # Transformação dos dados

1) Quadrado:

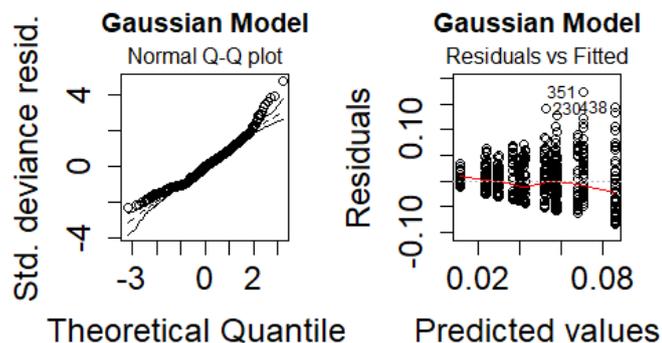
`hist((dados$Valor)^2)`

```

mquadrado<-glm((Valor)^2~Area+Indice,data=dados)
summary(mquadrado)
##
Call:
glm(formula = (valor)^2 ~ Area + Indice, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-0.083991 -0.029134 -0.000955 0.021544 0.174509
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 0.0425421 0.0039793 10.691 < 2e-16 ***
AreaCampo -0.0005411 0.0049284 -0.110 0.912610
AreaFloresta_Nativa 0.0101264 0.0048326 2.095 0.036500 *
AreaFloresta_Plantada 0.0276435 0.0048631 5.684 1.95e-08 ***
AreaPastagem_Nativa -0.0186292 0.0049634 -3.753 0.000189 ***
AreaPastagem_Plantada -0.0062247 0.0048631 -1.280 0.200989
IndiceNGRDI -0.0127782 0.0034685 -3.684 0.000248 ***
IndiceVARI 0.0152689 0.0034685 4.402 1.24e-05 ***

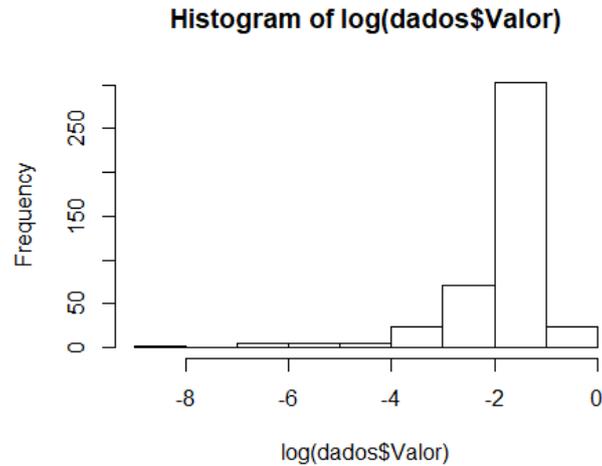
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.001383513)
##
Null deviance: 1.17408 on 689 degrees of freedom
Residual deviance: 0.94356 on 682 degrees of freedom
AIC: -2574.3
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mquadrado)

```



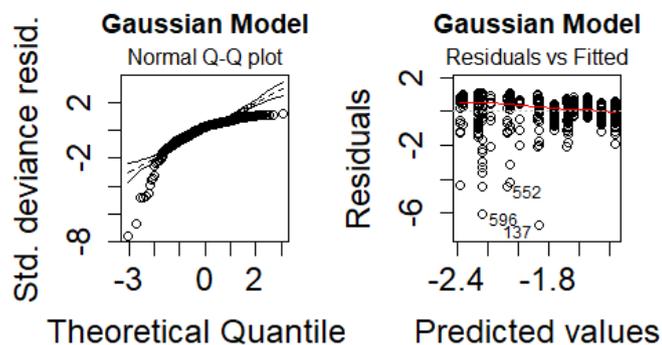
2) Log:

```
hist(log(dados$Valor))
Warning in log(dados$Valor): NaNs produzidos
```



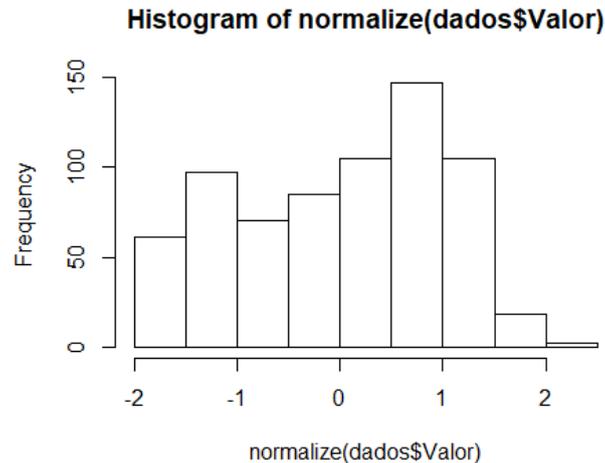
```
mlog<-glm(log(Valor)~Area+Indice,data=dados)
Warning in log(Valor): NaNs produzidos
summary(mlog)
##
Call:
glm(formula = log(Valor) ~ Area + Indice, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-6.7306 -0.3403 0.2550 0.5532 1.1098
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -2.0564 0.1835 -11.207 < 2e-16 ***
AreaCampo 0.1915 0.2207 0.868 0.38600
AreaFloresta_Nativa 0.4158 0.1952 2.131 0.03370 *
AreaFloresta_Plantada 0.5069 0.1957 2.591 0.00991 **
AreaPastagem_Nativa -0.2015 0.2103 -0.958 0.33853
AreaPastagem_Plantada -0.1789 0.2193 -0.816 0.41496
IndiceNGRDI -0.1247 0.1116 -1.117 0.26445
IndiceVARI 0.1827 0.1116 1.637 0.10229

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.9132613)
##
Null deviance: 433.60 on 435 degrees of freedom
Residual deviance: 390.88 on 428 degrees of freedom
(254 observations deleted due to missingness)
AIC: 1207.7
##
Number of Fisher scoring iterations: 2
diagnosticoModelo(mlog)
```



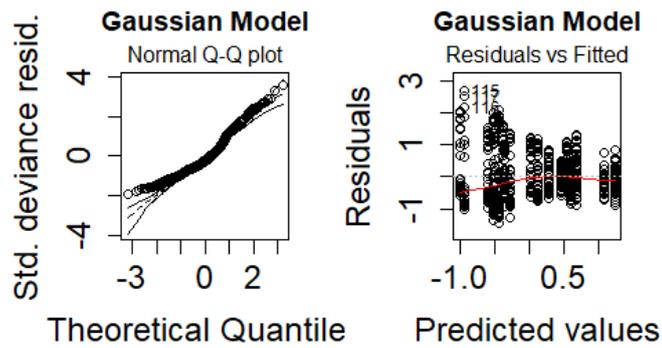
3) Normalizado:

```
library(BBmisc)
Warning: package 'BBmisc' was built under R version 3.5.3
##
Attaching package: 'BBmisc'
The following objects are masked from 'package:dplyr':
##
coalesce, collapse
The following object is masked from 'package:base':
##
isFALSE
hist(normalize(dados$Valor))
```



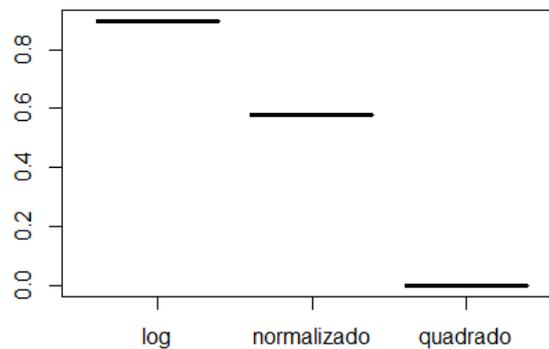
```
mnorm<-glm(normalize(Valor)~Area+Indice,data=dados)
summary(mnorm)
##
Call:
glm(formula = normalize(Valor) ~ Area + Indice, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-1.4566 -0.5234 -0.1867 0.4308 2.7145
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.38629 0.08175 -4.725 2.80e-06 ***
AreaCampo 0.50050 0.10125 4.943 9.68e-07 ***
AreaFloresta_Nativa 1.46851 0.09928 14.791 < 2e-16 ***
AreaFloresta_Plantada 1.61484 0.09991 16.163 < 2e-16 ***
AreaPastagem_Nativa 0.65461 0.10197 6.420 2.56e-10 ***
AreaPastagem_Plantada 0.40520 0.09991 4.056 5.58e-05 ***
IndiceNGRDI -0.62819 0.07126 -8.816 < 2e-16 ***
IndiceVARI -0.55565 0.07126 -7.798 2.37e-14 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.5839504)
##
Null deviance: 689.00 on 689 degrees of freedom
Residual deviance: 398.25 on 682 degrees of freedom
AIC: 1596.9
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mnorm)
```



### # Comparação dos resíduos

```
log<-mean(resid(mlog)^2)
normalizado<-mean(resid(mnorm)^2)
quadrado<-mean(resid(mquadrado)^2)
res<-data.frame(log,normalizado,quadrado)
boxplot(res)
```



### # Modelo Final

#### 1) Análise de variância

```
anova(mquadrado,test="F")
Analysis of Deviance Table
##
Model: gaussian, link: identity
##
Response: (valor)^2
##
Terms added sequentially (first to last)
##
Df Deviance Resid. Df Resid. Dev F Pr(>F)
NULL 689 1.17408
Area 5 0.139818 684 1.03426 20.212 < 2.2e-16 ***
Indice 2 0.090701 682 0.94356 32.779 2.555e-14 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

#### 2) Contrastes

```
attach(dados)
contrasteModelo(qvar="Indice",mma=mquadrado)

--- Starting the contrast analysis at 5 % ---

Actual levels in increasing order mean:
| NGRDI | GLI | VARI |
##
Result of contrast: NGRDI versus GLI
##
NGRDI and GLI are different

Actual levels in increasing order mean:
```

```

| NGRDI | GLI | VARI |
##
Result of contrast: GLI versus VARI
##
GLI and VARI are differents

##
----- Final result of the analysis of contrast -----
| NGRDI | GLI | VARI |

Mean by factor levels considering the analysis of contrast
NGRDI GLI VARI
0.03215404 0.04493221 0.06020113
detach(dados)

attach(dados)
contrasteModelo(qvar="Area",mma=mquadrado)

--- Starting the contrast analysis at 5 % ---

Actual levels in increasing order mean:
| Pastagem_Nativa | Pastagem_Plantada | Campo | Agricultura | Floresta_Nativa |
Floresta_Plantada |
##
Result of contrast: Pastagem_Nativa versus Pastagem_Plantada
##
Pastagem_Nativa and Pastagem_Plantada are differents

Actual levels in increasing order mean:
Pastagem_Nativa | Pastagem_Plantada | Campo | Agricultura | Floresta_Nativa |
Floresta_Plantada |
##
Result of contrast: Pastagem_Plantada versus Campo
##
Pastagem_Plantada and Campo are not differents

Actual levels in increasing order mean:
Pastagem_Nativa | Pastagem_PlantadaCampo | Agricultura | Floresta_Nativa |
Floresta_Plantada |
##
Result of contrast: Pastagem_PlantadaCampo versus Agricultura
##
Pastagem_PlantadaCampo and Agricultura are not differents

Actual levels in increasing order mean:
Pastagem_Nativa | Pastagem_PlantadaCampoAgricultura | Floresta_Nativa | Floresta_Plantada |
##
Result of contrast: Pastagem_PlantadaCampoAgricultura versus Floresta_Nativa
##
Pastagem_PlantadaCampoAgricultura and Floresta_Nativa are differents

Actual levels in increasing order mean:
Pastagem_Nativa | Pastagem_PlantadaCampoAgricultura | Floresta_Nativa | Floresta_Plantada |
##
Result of contrast: Floresta_Nativa versus Floresta_Plantada
##
Floresta_Nativa and Floresta_Plantada are differents

##
----- Final result of the analysis of contrast -----
Pastagem_Nativa | Pastagem_PlantadaCampoAgricultura | Floresta_Nativa | Floresta_Plantada |

Mean by factor levels considering the analysis of contrast
Pastagem_Nativa Pastagem_PlantadaCampoAgricultura
0.02474316 0.04108731
Floresta_Nativa Floresta_Plantada
0.05349880 0.07101589
detach(dados)

```

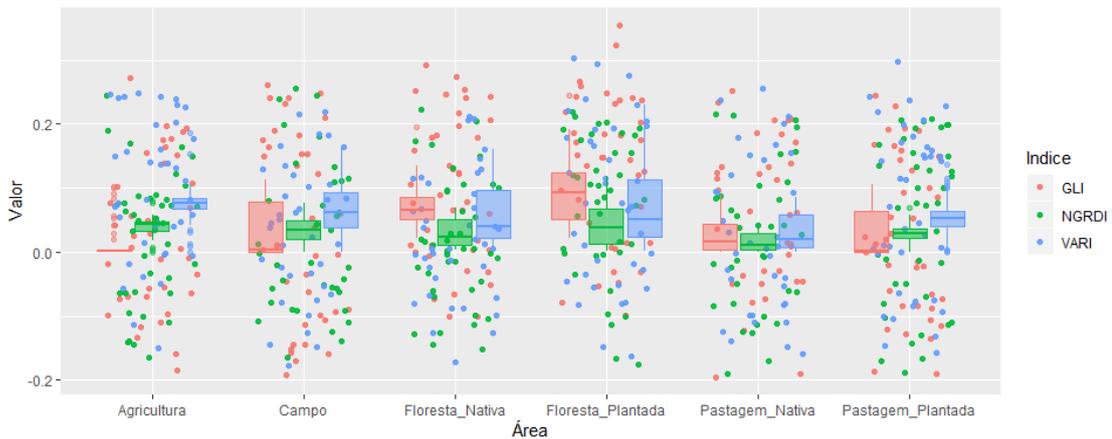
### 3) Gráfico

```

library(ggplot2)
valor<-(dados$valor)^2
ggplot(dados, aes(x=as.factor(Area), y=valor)) +
geom_jitter(position=position_jitter(width=0.3, height=0.2),
aes(colour=factor(Indice)), alpha=0.9) +

```

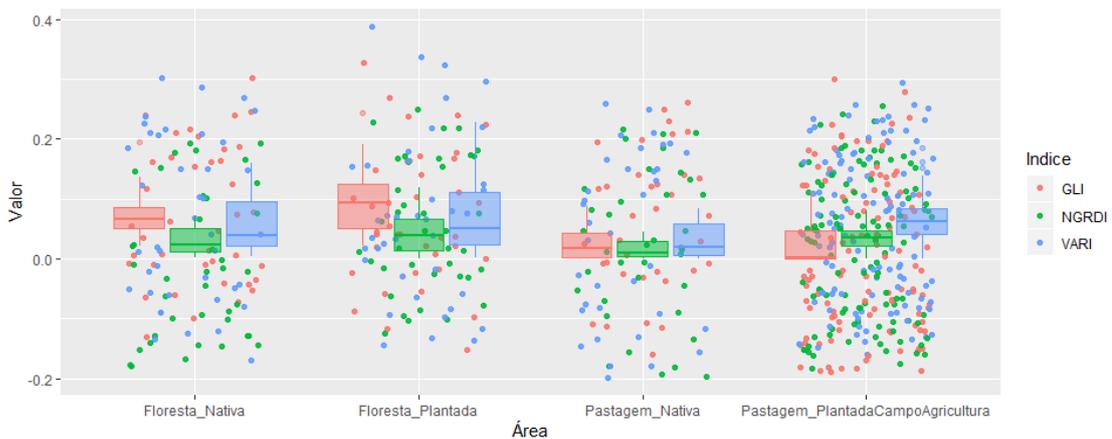
```
geom_boxplot(aes(color=as.factor(Indice),fill=Indice),
alpha =0.5, show.legend =FALSE) +
labs(x="Área", y="Valor",color="Indice")
```



#### 4) Gráfico de significância

```
dados2<-dados
levels(dados2$Indice)
[1] "GLI" "NGRDI" "VARI"
dados2$Indice<-as.character(dados2$Indice)
dados2$Indice[dados2$Indice == "GLI"]<-"GLI"
dados2$Indice[dados2$Indice == "NGRDI"]<-"NGRDI"
dados2$Indice[dados2$Indice == "VARI"]<-"VARI"
dados3<-dados2

levels(dados3$Area)
[1] "Agricultura" "Campo" "Floresta_Nativa"
[4] "Floresta_Plantada" "Pastagem_Nativa" "Pastagem_Plantada"
dados3$Area<-as.character(dados2$Area)
dados3$Area[dados3$Area == "Agricultura"]<-"Pastagem_PlantadaCampoAgricultura"
dados3$Area[dados3$Area == "Campo"]<-"Pastagem_PlantadaCampoAgricultura"
dados3$Area[dados3$Area == "Floresta_Nativa"]<-"Floresta_Nativa"
dados3$Area[dados3$Area == "Floresta_Plantada"]<-"Floresta_Plantada"
dados3$Area[dados3$Area == "Pastagem_Nativa"]<-"Pastagem_Nativa"
dados3$Area[dados3$Area == "Pastagem_Plantada"]<-"Pastagem_PlantadaCampoAgricultura"
library(ggplot2)
valor<-(dados$Valor)^2
ggplot(dados3, aes(x=as.factor(Area), y=valor)) +
geom_jitter(position=position_jitter(width=0.3, height=0.2),
aes(colour=factor(Indice)), alpha=0.9) +
geom_boxplot(aes(color=as.factor(Indice),fill=Indice),
alpha =0.5, show.legend =FALSE) +
labs(x="Área", y="Valor",color="Indice")
```



## APÊNDICE B.5 - ANÁLISES PARA DADOS AEROTRANSPORTADOS

### # Análises

#### 1) Descritiva básica:

```
summary(dados)
Area Índice Valor
Agricultura :36 GLI :72 Min. :-0.2584379
Campo :36 NGRDI:72 1st Qu.: -0.0007085
Floresta_Nativa :36 VARI :72 Median : 0.0770604
Floresta_Plantada:36 Mean : 0.0811897
Pastagem_Nativa :36 3rd Qu.: 0.1643276
Pastagem_Plantada:36 Max. : 0.3555557
```

#### 2) Descritiva com o pacote mosaic:

```
mean(Valor ~Area,data=dados)
Agricultura Campo Floresta_Nativa Floresta_Plantada
0.004332101 0.076133572 0.152118653 0.133304757
Pastagem_Nativa Pastagem_Plantada
0.071311265 0.049938016

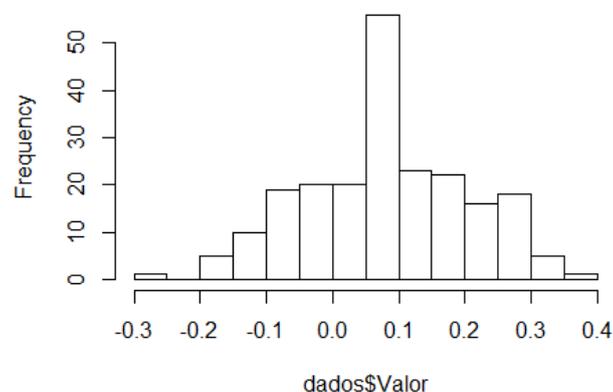
mean(Valor ~Indice,data=dados)
GLI NGRDI VARI
0.19152150 0.02475331 0.02729438

mean(Valor ~Area+Indice,data=dados)
Agricultura.GLI Campo.GLI Floresta_Nativa.GLI
0.12856475 0.19660484 0.23375030
Floresta_Plantada.GLI Pastagem_Nativa.GLI Pastagem_Plantada.GLI
0.24766849 0.17562049 0.16692011
Agricultura.NGRDI Campo.NGRDI Floresta_Nativa.NGRDI
-0.04964818 0.01671320 0.09781890
Floresta_Plantada.NGRDI Pastagem_Nativa.NGRDI Pastagem_Plantada.NGRDI
0.06899911 0.01910332 -0.00446650
Agricultura.VARI Campo.VARI Floresta_Nativa.VARI
-0.06592027 0.01508267 0.12478676
Floresta_Plantada.VARI Pastagem_Nativa.VARI Pastagem_Plantada.VARI
0.08324668 0.01920998 -0.01263956
```

#### 3) Histograma:

```
hist (dados$Valor);
```

Histogram of dados\$Valor

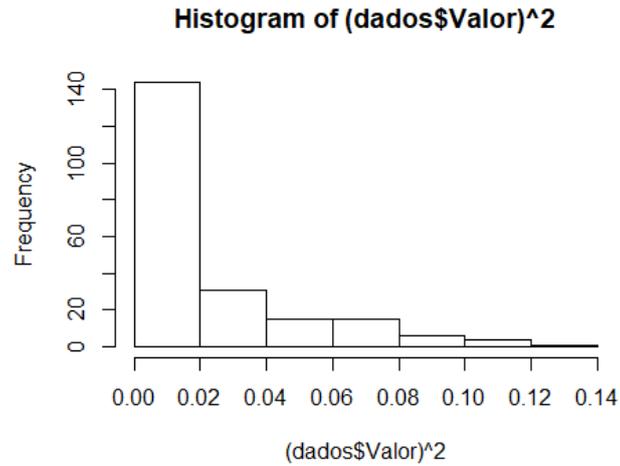


#### 4) Teste de Shapiro-wilk (SHAPIRO; WILK, 1965):

```
shapiro.test(dados$Valor)
##
Shapiro-wilk normality test
##
data: dados$Valor
w = 0.98969, p-value = 0.1249
```

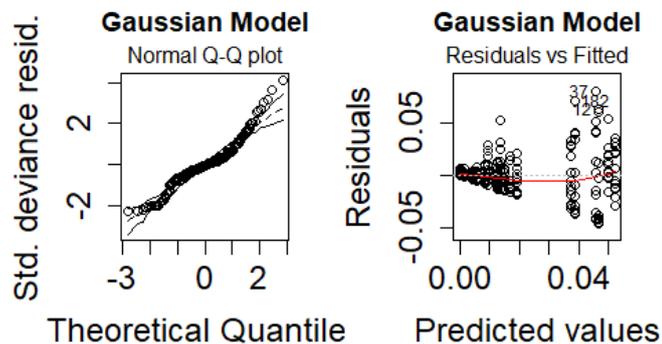
## # Transformação dos dados

1) Quadrado:

`hist((dados$Valor)^2)`

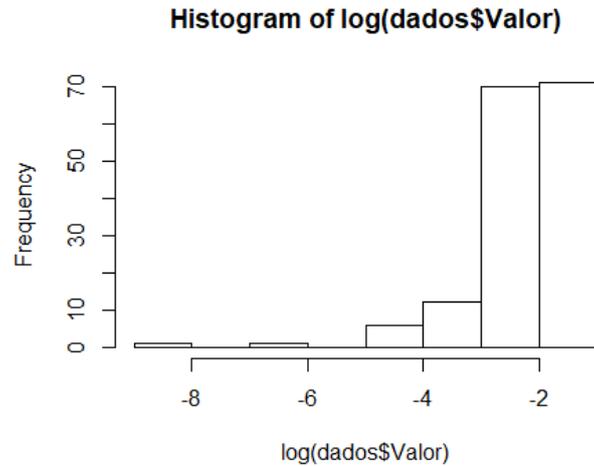
```
mquadrado<-glm((Valor)^2~Area+Indice,data=dados)
summary(mquadrado)
##
Call:
glm(formula = (valor)^2 ~ Area + Indice, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-0.046148 -0.009476 -0.001263 0.006447 0.080784
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 0.0466309 0.0039910 11.684 <2e-16 ***
AreaCampo -0.0009947 0.0048880 -0.204 0.8389
AreaFloresta_Nativa 0.0054999 0.0048880 1.125 0.2618
AreaFloresta_Plantada 0.0032818 0.0048880 0.671 0.5027
AreaPastagem_Nativa -0.0094646 0.0048880 -1.936 0.0542 .
AreaPastagem_Plantada -0.0080336 0.0048880 -1.644 0.1018
IndiceNGRDI -0.0371952 0.0034563 -10.761 <2e-16 ***
IndiceVARI -0.0329389 0.0034563 -9.530 <2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.0004300685)
##
Null deviance: 0.155627 on 215 degrees of freedom
Residual deviance: 0.089454 on 208 degrees of freedom
AIC: -1051.5
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mquadrado)
```



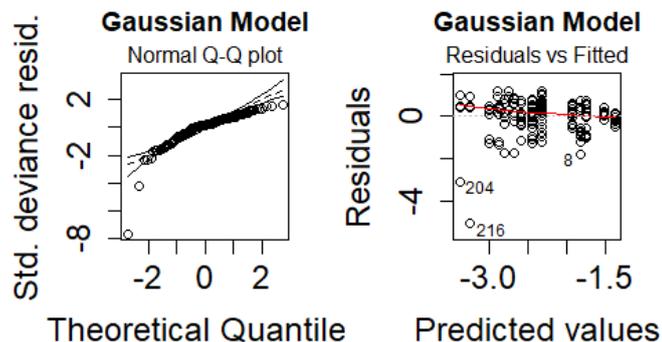
2) Log:

```
hist(log(dados$Valor))
Warning in log(dados$Valor): NaNs produzidos
```



```
mlog<-glm(log(Valor)~Area+Indice,data=dados)
Warning in log(Valor): NaNs produzidos
summary(mlog)
##
Call:
glm(formula = log(Valor) ~ Area + Indice, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-5.0819 -0.3519 0.1385 0.4885 1.2170
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.82298 0.19979 -9.125 3.94e-16 ***
AreaCampo 0.07638 0.25122 0.304 0.7615
AreaFloresta_Nativa 0.44339 0.23943 1.852 0.0660 .
AreaFloresta_Plantada 0.30491 0.24120 1.264 0.2081
AreaPastagem_Nativa -0.11369 0.25122 -0.453 0.6515
AreaPastagem_Plantada -0.49646 0.25923 -1.915 0.0573 .
IndiceNGRDI -1.06631 0.15507 -6.876 1.47e-10 ***
IndiceVARI -0.93542 0.15507 -6.032 1.17e-08 ***

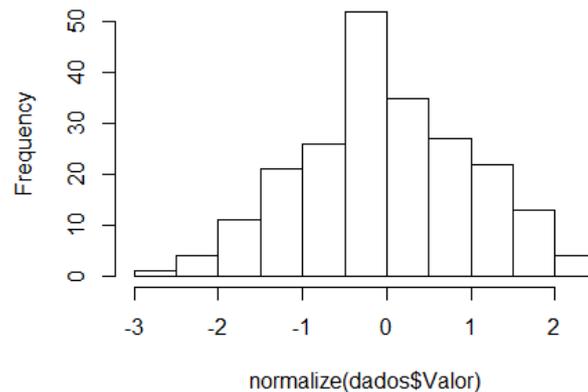
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.6427621)
##
Null deviance: 145.749 on 160 degrees of freedom
Residual deviance: 98.343 on 153 degrees of freedom
(55 observations deleted due to missingness)
AIC: 395.53
##
Number of Fisher scoring iterations: 2
diagnosticoModelo(mlog)
```



3) Normalizado:

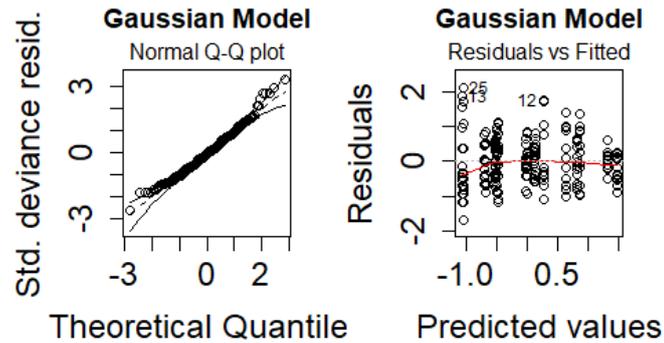
```
library(BBmisc)
Warning: package 'BBmisc' was built under R version 3.5.3
##
Attaching package: 'BBmisc'
The following objects are masked from 'package:dplyr':
##
coalesce, collapse
The following object is masked from 'package:base':
##
isFALSE
hist(normalize(dados$Valor))
```

Histogram of normalize(dados\$Valor)



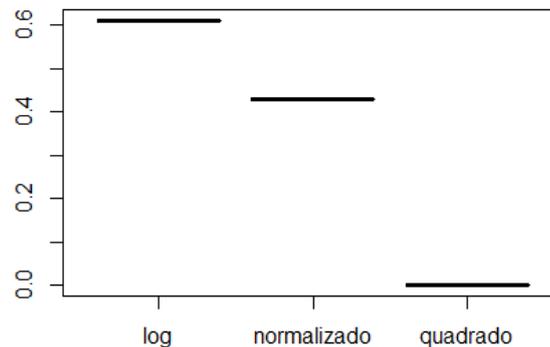
```
mnorm<-glm(normalize(Valor)~Area+Indice,data=dados)
summary(mnorm)
##
Call:
glm(formula = normalize(Valor) ~ Area + Indice, data = dados)
##
Deviance Residuals:
Min 1Q Median 3Q Max
-1.69909 -0.45461 -0.02491 0.41742 2.14466
##
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 0.2723 0.1286 2.118 0.035384 *
AreaCampo 0.5841 0.1575 3.709 0.000267 ***
AreaFloresta_Nativa 1.2022 0.1575 7.634 8.11e-13 ***
AreaFloresta_Plantada 1.0491 0.1575 6.662 2.37e-10 ***
AreaPastagem_Nativa 0.5448 0.1575 3.460 0.000656 ***
AreaPastagem_Plantada 0.3710 0.1575 2.356 0.019412 *
IndiceNGRDI -1.3566 0.1114 -12.183 < 2e-16 ***
IndiceVARI -1.3359 0.1114 -11.997 < 2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
(Dispersion parameter for gaussian family taken to be 0.4463714)
##
Null deviance: 215.000 on 215 degrees of freedom
Residual deviance: 92.845 on 208 degrees of freedom
AIC: 448.6
##
Number of Fisher Scoring iterations: 2
diagnosticoModelo(mnorm)
```



#### # Comparação dos resíduos

```
log<-mean(resid(mlog)^2)
normalizado<-mean(resid(mnorm)^2)
quadrado<-mean(resid(mquadrado)^2)
res<-data.frame(log,normalizado,quadrado)
boxplot(res)
```



#### # Modelo Final

##### 1) Análise de variância

```
anova(mquadrado,test="F")
Analysis of Deviance Table
##
Model: gaussian, link: identity
##
Response: (valor)^2
##
Terms added sequentially (first to last)
##
Df Deviance Resid. Df Resid. Dev F Pr(>F)
NULL 215 0.155627
Area 5 0.006495 210 0.149132 3.0203 0.01181 *
Indice 2 0.059678 208 0.089454 69.3816 < 2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

##### 2) Contrastes

```
attach(dados)
contrasteModelo(qvar="Indice",mma=mquadrado)

--- Starting the contrast analysis at 5 % ---

Actual levels in increasing order mean:
| NGRDI | VARI | GLI |
##
Result of contrast: NGRDI versus VARI
##
NGRDI and VARI are not different

```

```

Actual levels in increasing order mean:
| NGRDIVARI | GLI |
##
Result of contrast: NGRDIVARI versus GLI
##
NGRDIVARI and GLI are different
##
----- Final result of the analysis of contrast -----
| NGRDIVARI | GLI |

Mean by factor levels considering the analysis of contrast
NGRDIVARI GLI
0.009945293 0.045012340
detach(dados)

attach(dados)
contrasteModelo(qvar="Area",mma=mquadrado)

--- Starting the contrast analysis at 5 % ---

Actual levels in increasing order mean:
| Pastagem_Nativa | Pastagem_Plantada | Campo | Agricultura | Floresta_Plantada |
Floresta_Nativa |
##
Result of contrast: Pastagem_Nativa versus Pastagem_Plantada
##
Pastagem_Nativa and Pastagem_Plantada are not different

Actual levels in increasing order mean:
| Pastagem_NativaPastagem_Plantada | Campo | Agricultura | Floresta_Plantada |
Floresta_Nativa |
##
Result of contrast: Pastagem_NativaPastagem_Plantada versus Campo
##
Pastagem_NativaPastagem_Plantada and Campo are not different

Actual levels in increasing order mean:
Pastagem_NativaPastagem_PlantadaCampo | Agricultura | Floresta_Plantada | Floresta_Nativa |
##
Result of contrast: Pastagem_NativaPastagem_PlantadaCampo versus Agricultura
##
Pastagem_NativaPastagem_PlantadaCampo and Agricultura are not different

Actual levels in increasing order mean:
Pastagem_NativaPastagem_PlantadaCampoAgricultura | Floresta_Plantada | Floresta_Nativa |
##
Result of contrast: Pastagem_NativaPastagem_PlantadaCampoAgricultura versus
Floresta_Plantada
##
Pastagem_NativaPastagem_PlantadaCampoAgricultura and Floresta_Plantada are different

Actual levels in increasing order mean:
Pastagem_NativaPastagem_PlantadaCampoAgricultura | Floresta_Plantada | Floresta_Nativa |
##
Result of contrast: Floresta_Plantada versus Floresta_Nativa
##
Floresta_Plantada and Floresta_Nativa are not different

##
----- Final result of the analysis of contrast -----
| Pastagem_NativaPastagem_PlantadaCampoAgricultura | Floresta_PlantadaFloresta_Nativa |

Mean by factor levels considering the analysis of contrast
Pastagem_NativaPastagem_PlantadaCampoAgricultura Floresta_PlantadaFloresta_Nativa
0.01862962 0.02764368
detach(dados)

```

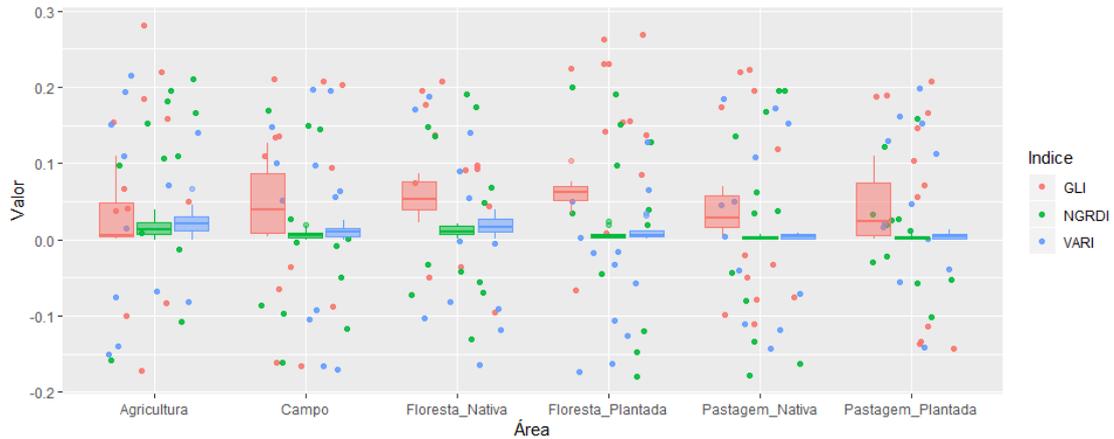
### 3) Gráfico

```

library(ggplot2)
valor<-(dados$valor)^2
ggplot(dados, aes(x=as.factor(Area), y=valor)) +
 geom_jitter(position=position_jitter(width=0.3, height=0.2),
 aes(colour=factor(Indice)), alpha=0.9) +
 geom_boxplot(aes(color=as.factor(Indice), fill=Indice),

```

```
alpha =0.5, show.legend =FALSE) +
labs(x="Área", y="Valor",color="Índice")
```

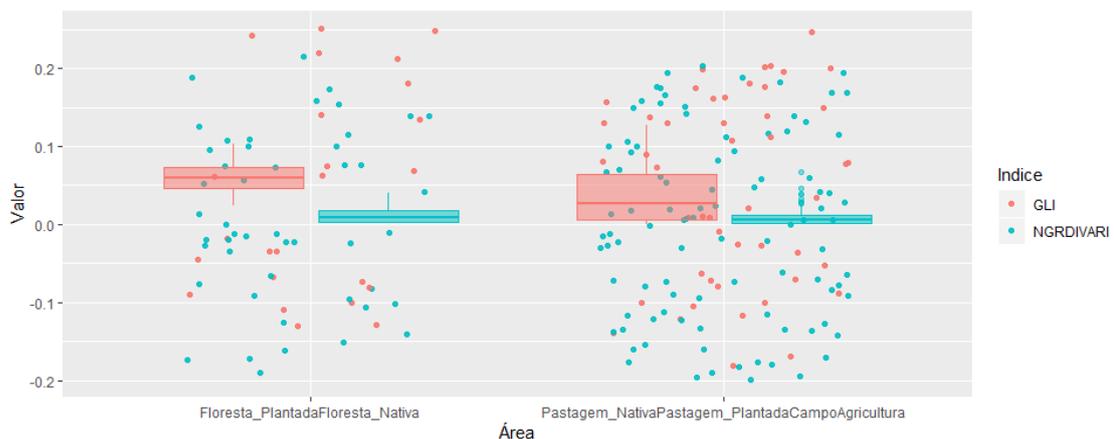


#### 4) Gráfico de significância

```
dados2<-dados
levels(dados2$Índice)
[1] "GLI" "NGRDI" "VARI"
dados2$Índice<-as.character(dados2$Índice)
dados2$Índice[dados2$Índice == "GLI"]<-"GLI"
dados2$Índice[dados2$Índice == "NGRDI"]<-"NGRDIVARI"
dados2$Índice[dados2$Índice == "VARI"]<-"NGRDIVARI"
dados3<-dados2

levels(dados3$Área)
[1] "Agricultura" "Campo" "Floresta_Nativa"
[4] "Floresta_Plantada" "Pastagem_Nativa" "Pastagem_Plantada"
dados3$Área<-as.character(dados2$Área)
dados3$Área[dados3$Área == "Agricultura"]<-"Pastagem_NativaPastagem_PlantadaCampoAgricultura"
dados3$Área[dados3$Área == "Campo"]<-"Pastagem_NativaPastagem_PlantadaCampoAgricultura"
dados3$Área[dados3$Área == "Floresta_Nativa"]<-"Floresta_PlantadaFloresta_Nativa"
dados3$Área[dados3$Área == "Floresta_Plantada"]<-"Floresta_PlantadaFloresta_Nativa"
dados3$Área[dados3$Área == "Pastagem_Nativa"]<-"Pastagem_NativaPastagem_PlantadaCampoAgricultura"
dados3$Área[dados3$Área == "Pastagem_Plantada"]<-"Pastagem_NativaPastagem_PlantadaCampoAgricultura"

library(ggplot2)
valor<-(dados3$Valor)^2
ggplot(dados3, aes(x=as.factor(Área), y=valor)) +
geom_jitter(position=position_jitter(width=0.3, height=0.2),
aes(colour=factor(Índice)), alpha=0.9) +
geom_boxplot(aes(color=as.factor(Índice),fill=Índice),
alpha =0.5, show.legend =FALSE) +
labs(x="Área", y="Valor",color="Índice")
```



## ANEXO A - IMAGENS ORBITAIS

**Tabela 5** - Relação de imagens Sentinel-2 utilizadas

CONDIÇÃO <sup>1</sup>	DATA	DIA	ACQUISITION START DATE	ACQUISITION END DATE	CLOUD COVER	VENDOR TILE ID
	04/02/2018	4	2018-02-04T13:24:07,479Z	2018-02-04T13:31:45,666Z	98,02	L1C_T23KLV_A004783_20180204T132407
	09/02/2018	9	2018-02-09T13:22:29,461Z	2018-02-09T13:31:30,627Z	69,39	L1C_T23KLV_A013763_20180209T132229
	14/02/2018	14	2018-02-14T13:26:12,750Z	2018-02-14T13:31:44,665Z	18,23	L1C_T23KLV_A004926_20180214T132612
	19/02/2018	19	2018-02-19T13:22:29,459Z	2018-02-19T13:29:27,960Z	86,80	L1C_T23KLV_A013906_20180219T132229
	24/02/2018	24	2018-02-24T13:22:24,460Z	2018-02-24T13:31:43,664Z	74,64	L1C_T23KLV_A005069_20180224T132224
	01/03/2018	29	2018-03-01T13:22:29,462Z	2018-03-01T13:31:48,667Z	06,85	L1C_T23KLV_A014049_20180301T132229
	06/03/2018	34	2018-03-06T13:26:32,395Z	2018-03-06T13:31:42,663Z	19,75	L1C_T23KLV_A005212_20180306T132632
	16/03/2018	44	2018-03-16T13:26:01,927Z	2018-03-16T13:31:44,665Z	08,47	L1C_T23KLV_A005355_20180316T132601
	21/03/2018	49	2018-03-21T13:22:30,458Z	2018-03-21T13:31:49,663Z	11,47	L1C_T23KLV_A014335_20180321T132230
	26/03/2018	54	2018-03-26T13:22:28,459Z	2018-03-26T13:31:47,664Z	06,50	L1C_T23KLV_A005498_20180326T132228
	31/03/2018	59	2018-03-31T13:24:17,082Z	2018-03-31T13:31:51,661Z	73,99	L1C_T23KLV_A014478_20180331T132417
	05/04/2018	64	2018-04-05T13:22:29,459Z	2018-04-05T13:31:48,664Z	13,58	L1C_T23KLV_A005641_20180405T132229
	10/04/2018	69	2018-04-10T13:22:33,460Z	2018-04-10T13:31:52,664Z	17,20	L1C_T23KLV_A014621_20180410T132233
	15/04/2018	74	2018-04-15T13:22:31,461Z	2018-04-15T13:31:47,058Z	68,75	L1C_T23KLV_A005784_20180415T132231
	20/04/2018	79	2018-04-20T13:22:34,464Z	2018-04-20T13:31:53,668Z	83,57	L1C_T23KLV_A014764_20180420T132234
	25/04/2018	84	2018-04-25T13:22:31,463Z	2018-04-25T13:31:50,668Z	01,60	L1C_T23KLV_A005927_20180425T132231
	30/04/2018	89	2018-04-30T13:23:40,397Z	2018-04-30T13:31:54,662Z	00,90	L1C_T23KLV_A014907_20180430T132340
	05/05/2018	94	2018-05-05T13:23:58,045Z	2018-05-05T13:31:50,663Z	00,06	L1C_T23KLV_A006070_20180505T132358
	10/05/2018	99	2018-05-10T13:22:35,457Z	2018-05-10T13:31:54,662Z	07,15	L1C_T23KLV_A015050_20180510T132235
	15/05/2018	104	2018-05-15T13:23:29,185Z	2018-05-15T13:31:50,665Z	00,64	L1C_T23KLV_A006213_20180515T132329

<sup>1</sup>**Verde:** imagens totalmente aptas; **Amarelo:** imagens parcialmente aptas; **Vermelho:** imagens inaptas a utilização.

CONDIÇÃO <sup>1</sup>	DATA	DIA	ACQUISITION START DATE	ACQUISITION END DATE	CLOUD COVER	VENDOR TILE ID
	20/05/2018	109	2018-05-20T13:22:35,463Z	2018-05-20T13:31:54,668Z	99,60	L1C_T23KLV_A015193_20180520T132235
	25/05/2018	114	2018-05-25T13:22:30,457Z	2018-05-25T13:29:46,998Z	37,05	L1C_T23KLV_A006356_20180525T132230
	30/05/2018	119	2018-05-30T13:22:34,463Z	2018-05-30T13:28:49,671Z	86,78	L1C_T23KLV_A015336_20180530T132234
	04/06/2018	124	2018-06-04T13:22:30,457Z	2018-06-04T13:28:49,273Z	31,72	L1C_T23KLV_A006499_20180604T132230
	09/06/2018	129	2018-06-09T13:22:32,462Z	2018-06-09T13:31:51,667Z	09,35	L1C_T23KLV_A015479_20180609T132232
	14/06/2018	134	2018-06-14T13:22:31,463Z	2018-06-14T13:31:18,198Z	00,00	L1C_T23KLV_A006642_20180614T132231
	19/06/2018	139	2018-06-19T13:22:32,460Z	2018-06-19T13:31:51,664Z	32,15	L1C_T23KLV_A015622_20180619T132232
	24/06/2018	144	2018-06-24T13:22:31,463Z	2018-06-24T13:31:50,668Z	70,81	L1C_T23KLV_A006785_20180624T132231
	29/06/2018	149	2018-06-29T13:22:33,464Z	2018-06-29T13:27:32,909Z	00,00	L1C_T23KLV_A015765_20180629T132233
	29/06/2018	149	2018-06-29T13:27:25,693Z	2018-06-29T13:31:52,669Z	00,00	L1C_T23KLV_A015765_20180629T132725
	04/07/2018	154	2018-07-04T13:22:31,458Z	2018-07-04T13:31:50,663Z	00,44	L1C_T23KLV_A006928_20180704T132231
	09/07/2018	159	2018-07-09T13:22:34,459Z	2018-07-09T13:31:53,663Z	00,00	L1C_T23KLV_A015908_20180709T132234
	14/07/2018	164	2018-07-14T13:22:31,460Z	2018-07-14T13:31:50,664Z	72,63	L1C_T23KLV_A007071_20180714T132231
	19/07/2018	169	2018-07-19T13:22:34,459Z	2018-07-19T13:31:53,663Z	00,06	L1C_T23KLV_A016051_20180719T132234
	24/07/2018	174	2018-07-24T13:24:07,872Z	2018-07-24T13:31:49,667Z	00,39	L1C_T23KLV_A007214_20180724T132407
	29/07/2018	179	2018-07-29T13:22:33,457Z	2018-07-29T13:36:41,283Z	01,63	L1C_T23KLV_A016194_20180729T132233
	03/08/2018	184	2018-08-03T13:22:29,458Z	2018-08-03T13:31:48,662Z	02,49	L1C_T23KLV_A007357_20180803T132229
	08/08/2018	189	2018-08-08T13:22:32,462Z	2018-08-08T13:31:51,666Z	00,11	L1C_T23KLV_A016337_20180808T132232
	13/08/2018	194	2018-08-13T13:22:27,461Z	2018-08-13T13:31:46,665Z	00,00	L1C_T23KLV_A007500_20180813T132227
	18/08/2018	199	2018-08-18T13:22:32,456Z	2018-08-18T13:31:51,660Z	31,84	L1C_T23KLV_A016480_20180818T132232
	23/08/2018	204	2018-08-23T13:22:25,464Z	2018-08-23T13:27:10,478Z	00,00	L1C_T23KLV_A007643_20180823T132225
	23/08/2018	204	2018-08-23T13:27:03,262Z	2018-08-23T13:31:44,669Z	06,96	L1C_T23KLV_A007643_20180823T132703
	28/08/2018	209	2018-08-28T13:22:31,463Z	2018-08-28T13:31:36,236Z	98,41	L1C_T23KLV_A016623_20180828T132231
	02/09/2018	214	2018-09-02T13:22:23,459Z	2018-09-02T13:27:19,297Z	00,00	L1C_T23KLV_A007786_20180902T132223
	02/09/2018	214	2018-09-02T13:27:12,081Z	2018-09-02T13:31:42,664Z	00,00	L1C_T23KLV_A007786_20180902T132712

CONDIÇÃO <sup>1</sup>	DATA	DIA	ACQUISITION START DATE	ACQUISITION END DATE	CLOUD COVER	VENDOR TILE ID
	07/09/2018	219	2018-09-07T13:22:30,460Z	2018-09-07T13:31:49,664Z	00,00	L1C_T23KLV_A016766_20180907T132230
	12/09/2018	224	2018-09-12T13:22:23,463Z	2018-09-12T13:30:34,120Z	00,00	L1C_T23KLV_A007929_20180912T132223
	17/09/2018	229	2018-09-17T13:22:28,461Z	2018-09-17T13:31:47,666Z	100,00	L1C_T23KLV_A016909_20180917T132228
	22/09/2018	234	2018-09-22T13:22:55,324Z	2018-09-22T13:31:45,667Z	01,85	L1C_T23KLV_A008072_20180922T132255
	02/10/2018	244	2018-10-02T13:22:28,460Z	2018-10-02T13:31:47,665Z	29,12	L1C_T23KLV_A008215_20181002T132228
	07/10/2018	249	2018-10-07T13:22:29,459Z	2018-10-07T13:31:48,664Z	100,00	L1C_T23KLV_A017195_20181007T132229
	12/10/2018	254	2018-10-12T13:26:49,220Z	2018-10-12T13:31:48,665Z	69,80	L1C_T23KLV_A008358_20181012T132649
	17/10/2018	259	2018-10-17T13:22:30,464Z	2018-10-17T13:31:49,668Z	81,90	L1C_T23KLV_A017338_20181017T132230
	22/10/2018	264	2018-10-22T13:22:30,460Z	2018-10-22T13:31:09,979Z	55,91	L1C_T23KLV_A008501_20181022T132230
	01/11/2018	274	2018-11-01T13:22:30,463Z	2018-11-01T13:31:49,668Z	94,99	L1C_T23KLV_A008644_20181101T132230
	06/11/2018	279	2018-11-06T13:22:28,463Z	2018-11-06T13:31:47,668Z	98,70	L1C_T23KLV_A017624_20181106T132228
	11/11/2018	284	2018-11-11T13:22:30,464Z	2018-11-11T13:31:49,669Z	68,68	L1C_T23KLV_A008787_20181111T132230
	16/11/2018	289	2018-11-16T13:22:27,460Z	2018-11-16T13:31:46,664Z	80,56	L1C_T23KLV_A017767_20181116T132227
	21/11/2018	294	2018-11-21T13:22:29,456Z	2018-11-21T13:31:48,661Z	98,69	L1C_T23KLV_A008930_20181121T132229
	26/11/2018	299	2018-11-26T13:22:25,458Z	2018-11-26T13:31:44,662Z	83,08	L1C_T23KLV_A017910_20181126T132225
	01/12/2018	304	2018-12-01T13:24:38,341Z	2018-12-01T13:31:47,665Z	94,14	L1C_T23KLV_A009073_20181201T132438
	06/12/2018	309	2018-12-06T13:22:24,460Z	2018-12-06T13:31:43,665Z	27,97	L1C_T23KLV_A018053_20181206T132224
	11/12/2018	314	2018-12-11T13:22:26,459Z	2018-12-11T13:31:45,664Z	25,59	L1C_T23KLV_A009216_20181211T132226
	16/12/2018	319	2018-12-16T13:22:24,458Z	2018-12-16T13:31:43,662Z	07,40	L1C_T23KLV_A018196_20181216T132224
	21/12/2018	324	2018-12-21T13:22:28,464Z	2018-12-21T13:31:47,669Z	00,56	L1C_T23KLV_A009359_20181221T132228
	26/12/2018	329	2018-12-26T13:22:26,457Z	2018-12-26T13:31:45,661Z	94,43	L1C_T23KLV_A018339_20181226T132226
	31/12/2018	334	2018-12-31T13:22:30,461Z	2018-12-31T13:31:49,665Z	30,70	L1C_T23KLV_A009502_20181231T132230
	05/01/2019	339	2019-01-05T13:22:28,456Z	2019-01-05T13:31:47,661Z	98,99	L1C_T23KLV_A018482_20190105T132228
	10/01/2019	344	2019-01-10T13:22:32,462Z	2019-01-10T13:31:51,666Z	16,53	L1C_T23KLV_A009645_20190110T132232
	15/01/2019	349	2019-01-15T13:22:29,461Z	2019-01-15T13:31:48,666Z	59,87	L1C_T23KLV_A018625_20190115T132229

<b>CONDIÇÃO <sup>1</sup></b>	<b>DATA</b>	<b>DIA</b>	<b>ACQUISITION START DATE</b>	<b>ACQUISITION END DATE</b>	<b>CLOUD COVER</b>	<b>VENDOR TILE ID</b>
	20/01/2019	354	2019-01-20T13:22:33,456Z	2019-01-20T13:31:52,661Z	11,73	L1C_T23KLV_A009788_20190120T132233
	25/01/2019	359	2019-01-25T13:22:30,459Z	2019-01-25T13:31:49,663Z	00,06	L1C_T23KLV_A018768_20190125T132230
	30/01/2019	364	2019-01-30T13:22:33,462Z	2019-01-30T13:31:52,666Z	00,11	L1C_T23KLV_A009931_20190130T132233

Fonte: USGS (2019)

**Figura 97** - 01/03/2018 (dia 29)



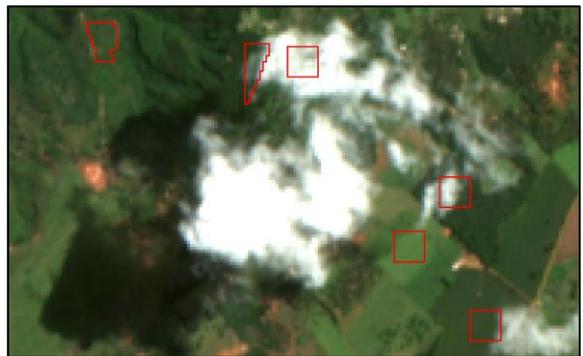
**Figura 98** - 06/03/2018 (dia 34)



**Figura 99** - 16/03/2018 (dia 44)



**Figura 100** - 21/03/2018 (dia 49)



**Figura 101** - 26/03/2018 (dia 54)



**Figura 102** - 05/04/2018 (dia 64)



**Figura 103** - 10/04/2018 (dia 69)



**Figura 104** - 25/04/2018 (dia 84)



**Figura 105** - 30/04/2018 (dia 89)



**Figura 106** - 05/05/2018 (dia 94)



**Figura 107** - 15/05/2018 (dia 104)



**Figura 108** - 09/06/2018 (dia 129)



**Figura 109** - 14/06/2018 (dia 134)



**Figura 110** - 29/06/2018 (dia 149)



**Figura 111** - 04/07/2018 (dia 154)



**Figura 112** - 09/07/2018 (dia 159)



**Figura 113** - 19/07/2018 (dia 169)



**Figura 114** - 24/07/2018 (dia 174)



**Figura 115** - 29/07/2018 (dia 179)



**Figura 116** - 03/08/2018 (dia 184)



**Figura 117** - 08/08/2018 (dia 189)



**Figura 118** - 13/08/2018 (dia 194)



**Figura 119** - 18/08/2018 (dia 199)



**Figura 120** - 23/08/2018 (dia 204)



**Figura 121** - 02/09/2018 (dia 214)



**Figura 122** - 07/09/2018 (dia 219)



**Figura 123** - 12/09/2018 (dia 224)



**Figura 124** - 22/09/2018 (dia 234)



**Figura 125** - 02/10/2018 (dia 244)



**Figura 126** - 16/12/2018 (dia 319)



**Figura 127** - 21/12/2018 (dia 324)



**Figura 128** - 10/01/2019 (dia 344)



**Figura 129** - 20/01/2019 (dia 354)



**Figura 130** - 25/01/2019 (dia 359)



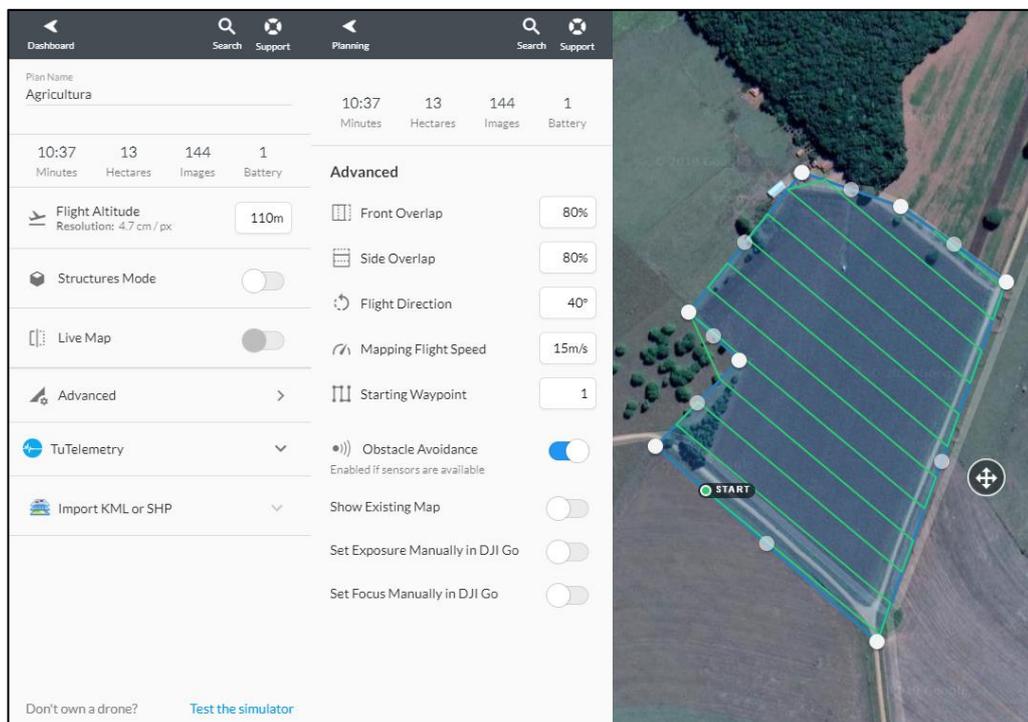
**Figura 131** - 30/01/2019 (dia 364)



Fonte: USGS (2019)

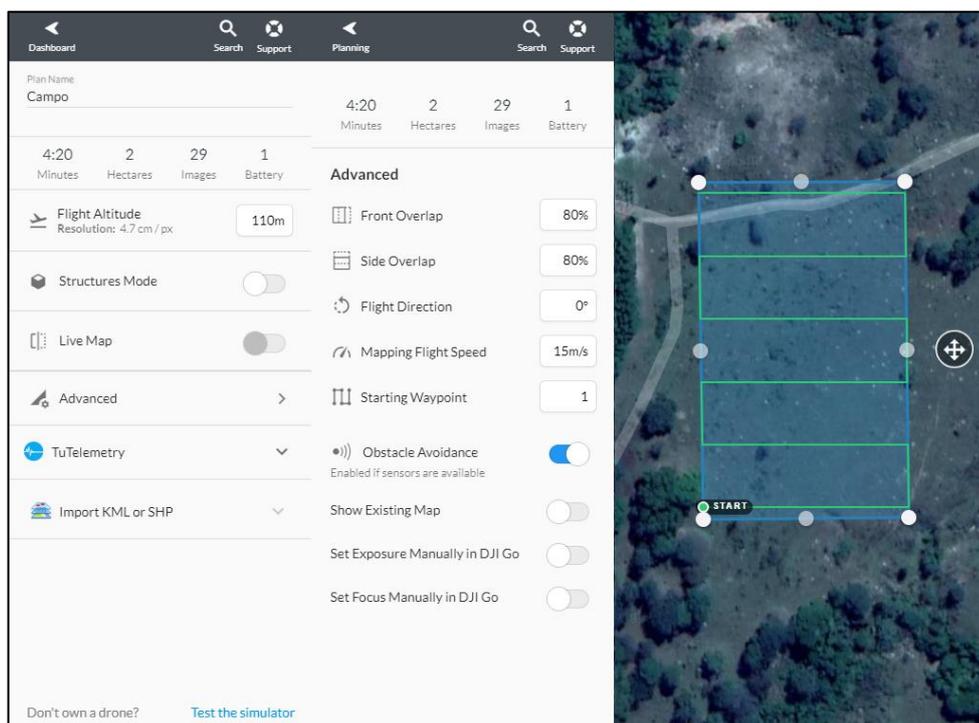
## ANEXO B - PLANOS DE VOO

**Figura 132** - Plano de voo para parcela amostral de agricultura



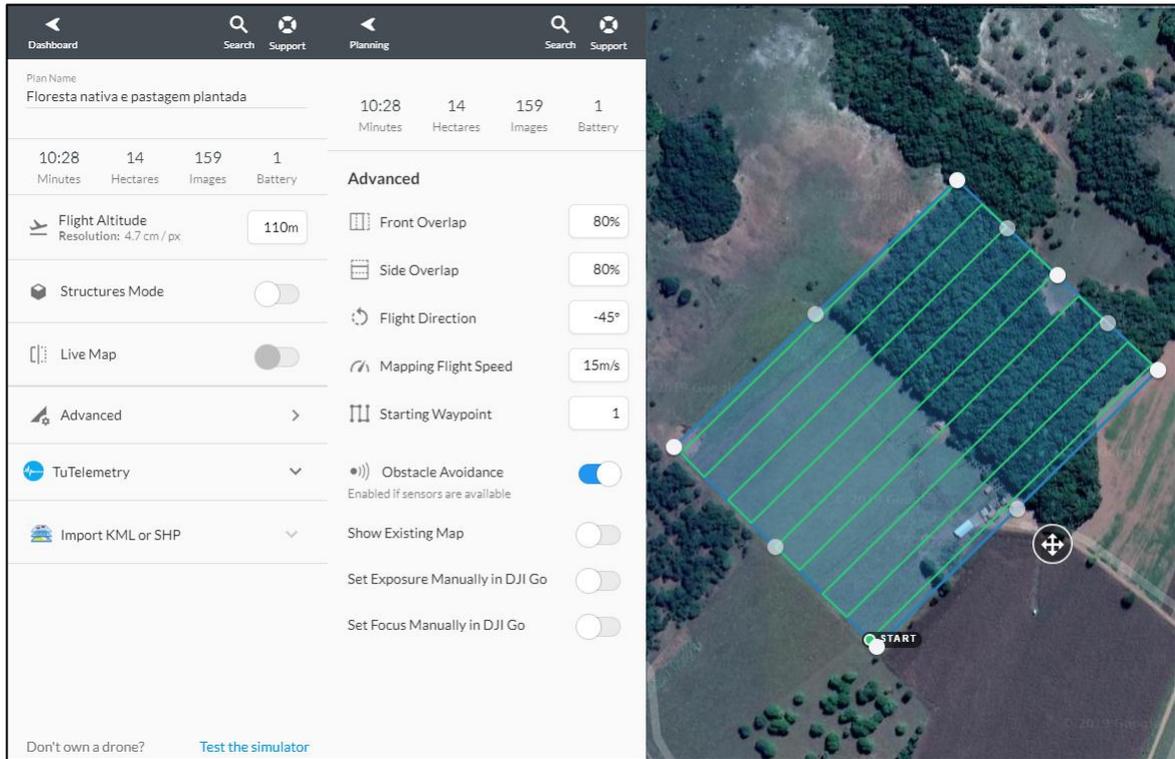
Fonte: INFATICS (2016)

**Figura 133** - Plano de voo para parcela amostral de campo



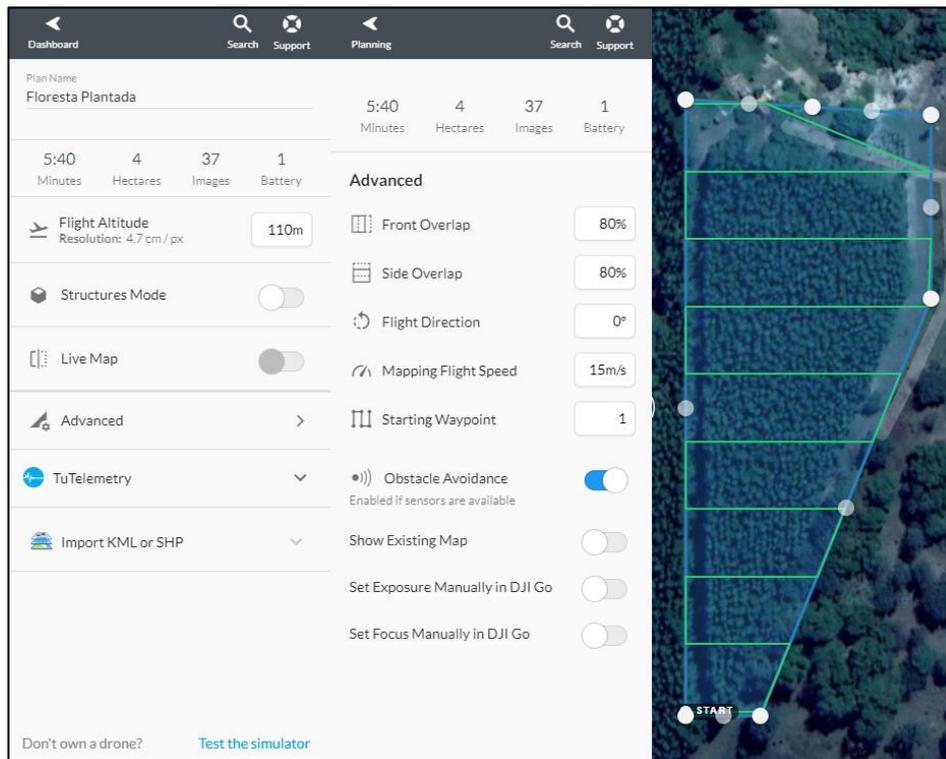
Fonte: INFATICS (2016)

**Figura 134 - Plano de voo para parcela amostral de floresta nativa e pastagem plantada**



Fonte: INFATICS (2016)

**Figura 135 - Plano de voo para parcela amostral de floresta plantada**



Fonte: INFATICS (2016)

**Figura 136** - Plano de voo para parcela amostral de pastagem nativa

The screenshot displays the DJI Go flight planning interface for a mission named "Pastagem nativa". The interface is divided into several sections:

- Plan Name:** Pastagem nativa
- Summary:** 4:15 Minutes, 3 Hectares, 33 Images, 1 Battery
- Advanced Settings:**
  - Flight Altitude: 110m (Resolution: 4.7 cm / px)
  - Structures Mode:
  - Live Map:
  - Advanced: >
  - TuTelemetry: v
  - Import KML or SHP: v
  - Front Overlap: 80%
  - Side Overlap: 80%
  - Flight Direction: 180°
  - Mapping Flight Speed: 15m/s
  - Starting Waypoint: 1
  - Obstacle Avoidance:  (Enabled if sensors are available)
  - Show Existing Map:
  - Set Exposure Manually in DJI Go:
  - Set Focus Manually in DJI Go:
- Map:** A satellite map showing a rectangular flight path with a "START" point at the top right corner. A zoom-in icon is visible at the bottom center of the map.

At the bottom left, there is a link: "Don't own a drone? [Test the simulator](#)".

Fonte: INFATICS (2016)

## ANEXO C - CERTIDÃO DE CADASTRO DE AERONAVE NÃO TRIPULADA

	REPÚBLICA FEDERATIVA DO BRASIL FEDERATIVE REPUBLIC OF BRAZIL	
	AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL NATIONAL CIVIL AVIATION AGENCY	

CERTIDÃO DE CADASTRO DE AERONAVE NÃO TRIPULADA – USO NÃO RECREATIVO UNMANNED AIRCRAFT REGISTER CERTIFICATE – NON-RECREATIONAL	
<p>Esta certidão de cadastro, emitida de acordo com o RBAC-E nº 94, é válida até <b>25/02/2020</b>, salvo em caso de cancelamento, suspensão ou revogação pela Autoridade de Aviação Civil Brasileira.</p> <p><i>This Register Certificate, issued in accordance with RBAC-E nr. 94, shall remain valid until <b>02/25/2020</b>, unless it is cancelled, suspended or revoked by the Brazilian Civil Aviation Authority.</i></p> <p>Operador (Operator) <b>DACIO JOSE CAMBRAIA FILHO</b></p> <p>CPF (document): 117.499.946-23</p>	<p><b>Nº do cadastro (Register Number):</b> <b>PP-156997600</b></p> <p>Uso (Purpose): não recreativo (non-recreational) Ramo de atividade (Business): Aerolevanteamento - Aerofotogrametria Fabricante (Maker): DJI Modelo (Model): Phantom 4 Nº de série (Serial Number): 15699760 Peso máximo de decolagem (MTOW): 1,38 kg Foto (Picture):</p> <div style="text-align: center;"></div>
<p><b>O descumprimento da regulamentação aplicável pode ensejar consequências administrativas, civis e/ou criminais para o infrator.</b></p>	<p>Informações adicionais (additional information):</p>
<p>O detentor desta certidão de cadastro (o operador) é considerado apto pela ANAC a realizar voos <b>recreativos e não recreativos</b> no Brasil, com a aeronave não tripulada acima identificada, em conformidade com os regulamentos aplicáveis da ANAC. É responsabilidade do operador tomar as providências necessárias para a operação segura da aeronave, assim como conhecer e cumprir os regulamentos do DECEA, da Anatel, e de outras autoridades competentes.</p> <p><i>The holder of this register certificate (the operator) is considered apt by Brazilian Civil Aviation Authority to perform <b>recreational and non-recreational</b> flights in Brazil, using the above identified unmanned aircraft, in conformity with the applicable regulations of Brazilian Civil Aviation Authority. It's the operator's responsibility to take the necessary actions to ensure a safe operation, as well as know and comply with the regulations of air traffic control (ATC), telecommunications, and other competent authorities</i></p>	
<p>A validade desta certidão pode ser verificada pelo link <a href="https://sistemas.anac.gov.br/SISANT/Aeronave/ConsultarAeronave">https://sistemas.anac.gov.br/SISANT/Aeronave/ConsultarAeronave</a></p>	
<p>Local e data da emissão (Place and date of issue) Brasília, 25 de fevereiro de 2018 <i>Brasília, February 25th, 2018</i></p>	
<p>Esta certidão de cadastro não é válida para aeronaves não tripuladas acima de 25 kg de peso máximo de decolagem, ou em voos além da linha de visada visual (BVLOS) ou acima de 400 pés ou 120 metros acima do nível do solo (AGL). <i>This register certificate is not valid for unmanned aircraft of more than 25 kg maximum takeoff weight, or flying beyond visual line of sight (BVLOS) or over 400 feet or 120 meters above ground level (AGL).</i></p>	

## ANEXO D - SÉRIES HISTÓRICAS PLUVIOMÉTRICAS

**Tabela 6** - Pluviometria média na estação do Pântano (código 01846006)

Ano	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro	Soma
1976	69,30	269,90	142,10	65,90	39,00	0,00	50,90	0,40	131,60	125,80	276,90	389,90	1561,70
1977	372,20	18,90	39,40	87,20	59,20	6,70	0,00	3,00	66,10	190,60	324,70	370,80	1538,80
1978	348,20	196,70	91,00	99,00	219,00	13,00	7,00	0,00	46,50	160,00	344,10	560,00	2084,50
1979	289,50	519,50	77,90	132,80	76,00	0,00	13,60	41,00	214,50	155,80	225,00	396,00	2141,60
1980	493,40	275,00	110,80	98,00	25,00	27,00	0,00	5,00	36,00	42,00	362,00	376,00	1850,20
1981	389,00	57,00	296,00	29,30	8,00	42,00	0,00	7,00	5,00	146,00	489,00	195,00	1663,30
1982	435,00	130,50	479,00	41,50	73,00	0,00	11,00	1,00	14,50	118,40	63,50	381,00	1748,40
1983	515,30	504,50	144,50	113,00	14,00	9,00	48,50	8,00	39,50	231,00	345,00	365,50	2337,80
1984	158,00	58,20	190,40	75,10	25,10	0,00	0,00	49,50	100,00	108,00	179,30	222,20	1165,80
1985	580,00	114,50	240,00	62,30	8,50	0,00	0,00	0,00	93,30	88,00	326,50	263,00	1776,10
1986	344,50	339,50	95,50	28,00	28,70	1,00	132,00	75,70	23,90	52,50	66,50	450,00	1637,80
1987	213,50	79,70	210,90	76,30	78,80	5,70	0,00	6,50	80,60	137,40	122,30	477,10	1488,80
1988	250,10	254,50	155,80	90,70	2,80	5,80	0,00	0,00	17,00	170,00	116,00	268,00	1330,70
1989	158,10	377,40	94,10	68,70	2,30	33,40	15,50	34,40	42,60	170,20	317,50	353,00	1667,20
1990	79,80	232,80	119,40	18,40	21,30	0,00	42,60	17,40	61,30	228,10	148,70	122,90	1092,70
1991	545,80	207,80	389,30	103,30	23,50	0,00	0,00	0,00	70,20	126,70	135,80	238,40	1840,80
1992	681,30	489,70	109,70	139,30	21,40	0,00	0,00	3,00	87,10	227,20	198,50	403,30	2360,50
1993	68,70	326,70	71,60	80,60	6,30	14,00	0,00	14,60	8,60	117,10	155,30	339,70	1203,20
1994	392,50	15,90	363,10	50,20	39,60	8,50	5,10	0,00	3,50	108,50	242,60	319,20	1548,70
1995	153,90	466,10	246,90	50,20	86,30	0,00	0,00	0,00	27,00	116,40	165,70	417,70	1730,20
1996	165,80	251,50	64,40	29,30	51,50	0,00	12,70	3,50	84,90	96,50	415,40	315,50	1491,00

<b>Ano</b>	<b>Janeiro</b>	<b>Fevereiro</b>	<b>Março</b>	<b>Abril</b>	<b>Mai</b>	<b>Junho</b>	<b>Julho</b>	<b>Agosto</b>	<b>Setembro</b>	<b>Outubro</b>	<b>Novembro</b>	<b>Dezembro</b>	<b>Soma</b>
<b>1997</b>	451,00	82,50	261,10	166,10	34,10	69,10	6,40	0,00	62,60	69,40	228,60	401,30	1832,20
<b>1998</b>	235,60	265,20	102,20	78,20	75,90	21,00	2,00	64,40	0,30	82,20	149,30	204,90	1281,20
<b>1999</b>	228,50	183,10	262,00	26,00	6,00	11,10	21,50	0,00	52,70	65,30	255,90	238,20	1350,30
<b>2000</b>	404,10	265,20	132,30	43,60	0,00	0,00	1,50	16,30	57,00	25,00	268,90	249,70	1463,60
<b>2001</b>	218,60	70,10	361,70	1,60	29,00	0,00	1,70	21,10	31,10	133,40	302,60	374,70	1545,60
<b>2002</b>	365,30	362,90	103,20	4,90	61,10	0,00	2,50	9,10	46,00	34,00	57,10	318,10	1364,20
<b>2003</b>	519,30	111,00	241,40	47,30	30,60	0,00	0,00	2,60	43,70	42,70	157,60	110,60	1306,80
<b>2004</b>	491,20	393,90	196,60	156,30	2,90	0,00	16,70	0,00	5,00	69,90	148,30	364,50	1845,30
<b>2005</b>	418,40	73,60	274,50	78,30	22,00	5,00	0,00	13,80	36,40	30,60	472,40	513,80	1938,80
<b>2006</b>	215,80	221,70	423,90	96,30	27,90	0,00	0,00	11,20	140,00	232,80	330,40	611,00	2311,00
<b>2007</b>	724,50	399,70	73,30	216,20	3,00	4,20	48,20	0,00	13,20	56,80	166,20	224,70	1930,00
<b>2008</b>	362,00	365,80	221,80	229,30	17,00	0,00	23,80	0,00	129,90	49,80	183,70	590,30	2173,40
<b>2009</b>	401,00	259,40	149,50	88,10	31,90	35,10	0,00	85,10	15,10	173,80	235,30	376,20	1850,50
<b>2010</b>	224,90	121,00	206,70	53,70	20,70	9,30	0,00	52,90	0,00	155,60	326,00	330,40	1501,20
<b>2011</b>	519,20	108,40	519,00	59,10	10,50	7,50	0,00	0,00	0,00	207,70	129,80	551,00	2112,20
<b>2012</b>	352,00	152,50	90,70	111,30	26,20	67,40	0,00	0,00	37,50	34,90	415,90	170,40	1458,80
<b>2013</b>	325,70	69,60	226,30	121,70	61,00	8,00	0,00	2,70	23,80	115,80	308,90	294,00	1557,50
<b>2014</b>	233,60	61,40	121,70	152,80	14,70	0,00	64,50	9,10	0,00	152,90	299,60	219,10	1329,40
<b>2015</b>	89,80	333,60	285,90	104,70	97,50	0,00	0,00	0,00	50,30	-	209,20	192,30	1363,30
<b>2016</b>	485,50	190,30	107,30	21,00	32,60	5,30	0,00	5,80	7,00	72,90	283,30	184,50	1395,50
<b>2017</b>	107,10	276,90	92,30	20,00	75,50	0,00	0,00	0,00	0,00	86,60	228,70	252,40	1139,50
<b>2018</b>	206,90	218,20	261,80	39,50	8,10	0,00	0,00	15,9	42,70	-	-	-	-
<b>Média</b>	332,18	227,26	196,44	80,35	37,15	9,51	12,27	13,49	47,63	117,28	242,33	333,25	1650,24

Fonte: ANA (2019)

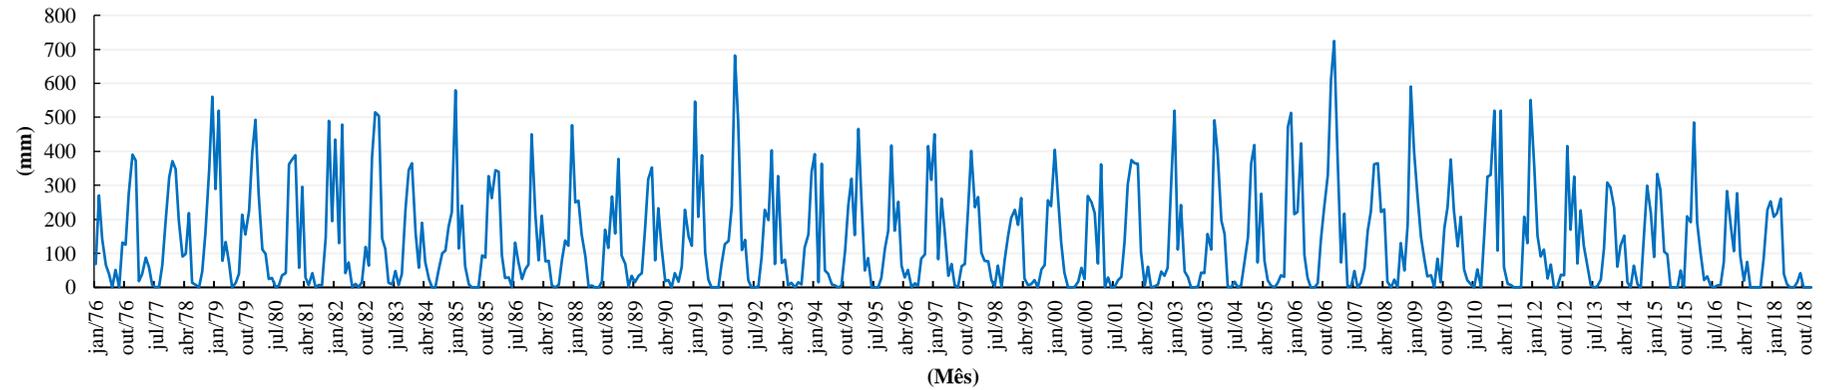
**Tabela 7** - Pluviometria média na estação da Rocinha (código 01846019)

<b>Ano</b>	<b>Janeiro</b>	<b>Fevereiro</b>	<b>Março</b>	<b>Abril</b>	<b>Mai</b>	<b>Junho</b>	<b>Julho</b>	<b>Agosto</b>	<b>Setembro</b>	<b>Outubro</b>	<b>Novembro</b>	<b>Dezembro</b>	<b>Soma</b>
<b>1978</b>	361,30	220,10	178,00	70,00	62,50	4,00	18,30	0,00	25,50	103,50	308,00	383,80	1735,00
<b>1979</b>	301,30	361,80	171,40	65,30	67,20	0,00	12,20	44,60	55,10	41,70	136,70	249,70	1507,00
<b>1980</b>	386,10	295,70	29,00	102,60	2,70	17,30	0,00	2,20	25,50	54,00	347,80	399,50	1662,40
<b>1981</b>	423,80	48,60	259,30	35,30	18,40	28,80	7,40	0,90	0,00	169,40	330,20	336,00	1658,10
<b>1982</b>	396,70	93,80	456,60	33,10	59,70	0,00	9,60	9,90	14,10	125,80	95,10	314,40	1608,80
<b>1983</b>	431,70	424,40	156,80	136,30	17,00	9,80	41,60	6,60	13,00	213,10	348,90	309,50	2108,70
<b>1984</b>	114,10	34,40	57,40	35,50	15,90	0,00	0,60	78,00	113,70	38,60	151,40	225,80	865,40
<b>1985</b>	602,30	69,20	192,90	60,10	4,70	0,00	4,90	2,10	59,00	91,50	183,50	319,10	1589,30
<b>1986</b>	405,60	263,90	125,00	25,40	28,00	0,00	18,80	78,30	40,40	83,00	54,00	380,00	1502,40
<b>1987</b>	204,00	151,40	113,20	70,40	13,60	21,90	0,00	6,60	104,20	144,60	167,70	583,10	1580,70
<b>1988</b>	142,50	300,10	192,50	62,30	7,40	71,20	0,00	0,00	15,80	269,20	166,40	205,60	1433,00
<b>1989</b>	190,20	361,70	121,00	35,20	0,10	26,90	0,00	51,80	32,80	63,30	234,60	463,90	1581,50
<b>1990</b>	92,00	174,90	123,60	13,10	38,00	0,00	39,70	30,90	63,70	81,80	66,80	104,40	828,90
<b>1991</b>	405,90	222,80	318,90	65,30	27,00	0,00	0,00	0,00	69,10	92,20	113,20	450,80	1765,20
<b>1992</b>	654,80	284,50	129,70	73,80	15,90	0,00	0,00	0,00	117,40	171,90	437,50	300,60	2186,10
<b>1993</b>	114,00	238,60	20,20	132,10	4,70	9,10	0,00	3,00	5,90	144,20	231,00	471,60	1374,40
<b>1994</b>	248,70	67,00	251,00	45,00	64,00	10,00	3,00	0,00	1,20	93,00	214,00	269,90	1266,80
<b>1995</b>	185,20	354,00	219,20	59,10	136,00	0,00	0,00	0,00	37,00	136,00	150,00	389,20	1665,70
<b>1996</b>	244,20	149,00	121,70	120,70	20,80	0,00	10,70	7,70	73,50	60,60	371,90	276,40	1457,20
<b>1997</b>	344,00	152,80	204,10	121,20	31,40	36,50	0,00	0,00	19,00	81,00	230,40	272,80	1493,20
<b>1998</b>	262,70	356,80	28,10	57,60	50,50	0,00	0,00	30,80	3,60	81,80	165,50	227,40	1264,80
<b>1999</b>	128,10	156,00	243,00	43,50	12,90	2,90	0,40	0,00	37,80	66,20	263,90	197,50	1152,20
<b>2000</b>	369,80	234,60	127,80	73,10	0,00	0,00	0,90	10,00	76,60	51,30	245,00	360,30	1549,40

<b>Ano</b>	<b>Janeiro</b>	<b>Fevereiro</b>	<b>Março</b>	<b>Abril</b>	<b>Maior</b>	<b>Junho</b>	<b>Julho</b>	<b>Agosto</b>	<b>Setembro</b>	<b>Outubro</b>	<b>Novembro</b>	<b>Dezembro</b>	<b>Soma</b>
<b>2001</b>	93,50	239,00	123,90	29,80	23,50	0,00	1,50	19,90	51,50	307,60	87,30	250,40	1227,90
<b>2002</b>	147,50	239,00	123,90	29,80	23,50	0,00	1,50	0,00	45,10	31,80	40,90	338,60	1021,60
<b>2003</b>	548,20	80,20	182,30	9,10	27,60	0,00	0,00	0,10	55,10	56,60	198,80	182,60	1340,60
<b>2004</b>	463,20	258,40	165,20	108,00	27,10	0,00	17,90	0,00	0,60	28,70	104,80	302,80	1476,70
<b>2005</b>	395,10	71,30	207,00	27,70	6,60	4,60	0,00	11,40	38,00	27,40	483,10	357,20	1629,40
<b>2006</b>	254,00	142,00	265,60	138,30	4,60	0,20	0,10	4,60	111,20	291,20	191,80	517,20	1920,80
<b>2007</b>	563,70	295,90	66,30	62,90	4,30	0,00	19,50	0,00	3,10	46,60	68,70	257,60	1388,60
<b>2008</b>	189,70	351,20	214,90	130,30	20,10	1,80	0,00	0,00	53,40	27,20	119,50	393,70	1501,80
<b>2009</b>	-	168,50	224,50	117,00	19,40	37,20	0,20	31,90	84,00	205,10	299,80	367,50	1555,10
<b>2010</b>	214,90	81,20	90,50	77,80	7,60	7,80	0,00	0,00	14,30	98,80	265,90	-	858,80
<b>2011</b>	494,40	129,90	474,10	40,90	0,00	4,40	0,00	0,00	4,60	217,60	93,30	467,10	1926,30
<b>2012</b>	321,00	127,20	167,70	37,10	17,30	72,20	0,00	0,00	32,00	46,50	410,10	126,20	1357,30
<b>2013</b>	344,30	79,10	166,20	185,00	20,10	3,00	0,00	6,30	23,70	118,20	255,50	311,40	1512,80
<b>2014</b>	76,70	112,00	192,60	107,00	10,20	3,80	48,60	0,00	4,10	57,20	333,90	230,70	1176,80
<b>2015</b>	71,90	301,60	220,40	60,60	72,50	2,10	0,00	0,00	69,40	64,80	173,80	95,70	1132,80
<b>2016</b>	450,30	141,60	130,70	27,20	0,00	5,60	0,00	3,90	10,50	70,00	267,40	187,80	1295,00
<b>2017</b>	98,10	165,10	181,60	14,60	51,50	1,40	0,00	0,00	0,00	78,60	240,40	215,20	1046,50
<b>2018</b>	156,80	184,50	211,60	71,30	3,20	0,00	0,00	25,40	41,30	77,80	354,30	381,10	1507,30
<b>Média</b>	297,31	199,60	176,81	68,55	25,30	9,33	6,28	11,39	40,14	105,11	219,58	294,05	1385,85

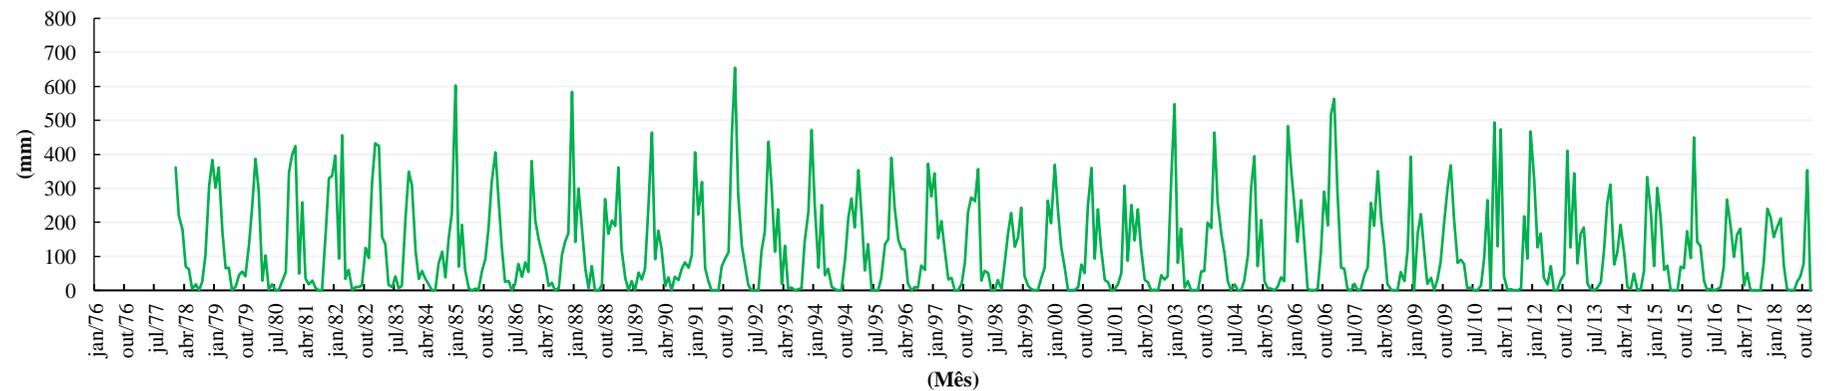
Fonte: ANA (2019)

**Figura 137 - Série histórica pluviométrica da estação do Pântano (código 01846006)**



Fonte: ANA (2019)

**Figura 138 - Série histórica pluviométrica da estação da Rocinha (código 01846019)**



Fonte: ANA (2019)