

FELIPE DE SOUZA NOGUEIRA TAGLIARINI

**IMAGENS DE DRONE E ÍNDICE DE VEGETAÇÃO POR DIFERENÇA
NORMALIZADA (NDVI) PARA CLASSIFICAÇÃO SEGMENTADA EM ÁREAS DE
PRESERVAÇÃO PERMANENTE (APP)**

Botucatu

2020

FELIPE DE SOUZA NOGUEIRA TAGLIARINI

**IMAGENS DE DRONE E ÍNDICE DE VEGETAÇÃO POR DIFERENÇA
NORMALIZADA (NDVI) PARA CLASSIFICAÇÃO SEGMENTADA EM ÁREAS DE
PRESERVAÇÃO PERMANENTE (APP)**

Tese apresentada à Faculdade de Ciências
Agronômicas da Unesp Câmpus de Botucatu,
Programa de Pós-Graduação em Agronomia
(Energia na Agricultura)

Orientador: Prof. Dr. Sérgio Campos

Coorientador: Prof. Dr. Mikael Timóteo Rodrigues

Botucatu

2020

T126i

Tagliarini, Felipe de Souza Nogueira

Imagens de drone e Índice de Vegetação por Diferença Normalizada (NDVI)
para classificação segmentada em Áreas de Preservação Permanente (APP) /
Felipe de Souza Nogueira Tagliarini. -- Botucatu, 2020

148 p. : il., tabs., fotos, mapas

Tese (doutorado) - Universidade Estadual Paulista (Unesp), Faculdade de
Ciências Agrônômicas, Botucatu

Orientador: Sérgio Campos

Coorientador: Mikael Timóteo Rodrigues

1. Geomática. 2. Sensoriamento remoto. 3. Drone. 4. Fotogrametria aérea. 5.
Índice de Vegetação por Diferença Normalizada. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências
Agrônômicas, Botucatu. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: IMAGENS DE DRONE E ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA (NDVI) PARA CLASSIFICAÇÃO SEGMENTADA EM ÁREAS DE PRESERVAÇÃO PERMANENTE (APP)

AUTOR: FELIPE DE SOUZA NOGUEIRA TAGLIARINI
ORIENTADOR: SÉRGIO CAMPOS
COORIENTADOR: MIKAEL TIMÓTEO RODRIGUES

Aprovado como parte das exigências para obtenção do Título de Doutor em AGRONOMIA (ENERGIA NA AGRICULTURA), pela Comissão Examinadora:

Prof. Dr. SÉRGIO CAMPOS (Participação Virtual)
Engenharia Rural e Socioeconomia / Faculdade de Ciências Agronômicas de Botucatu - UNESP



Dr.ª YARA MANFRIN GARCIA (Participação Virtual)
Bauru/SP / .



Prof. Dr. OSMAR DELMANTO JUNIOR (Participação Virtual)
Agronegócio / Faculdade de Tecnologia de Botucatu



Prof. Dr. EDSON LUÍS PIROLI (Participação Virtual)
Coordenadoria Executiva / UNESP - Campus de Ourinhos



Prof.ª Dr.ª FERNANDA LEITE RIBEIRO (Participação Virtual)
Geociências / Universidade Estadual de Londrina



Botucatu, 16 de dezembro de 2020

A toda minha família e amigos,
Em especial, minha amada mãe Gisele,
Dedico!

AGRADECIMENTOS ESPECIAIS

Ao meu orientador, Prof. Dr. Sérgio Campos, por toda a orientação, convivência e pela confiança depositada em minha pessoa, proporcionando a oportunidade no meio acadêmico e de desenvolver um doutorado. E principalmente pela amizade e por todos os ensinamentos.

Ao meu coorientador, Prof. Dr. Mikael Timóteo Rodrigues, por toda a amizade, companheirismo, parceria e pela sua imensa disponibilidade em ajudar. Por ser um verdadeiro mentor e por toda a troca de experiências, oferecendo todo o suporte necessário, que foram fundamentais para a realização deste trabalho.

AGRADECIMENTOS

A Deus primeiramente, por ser tão bom e por tudo o que me proporcionou durante minha vida, inclusive chegar a esse grande sonho de ingressar e finalizar o doutorado.

A toda a minha família, em especial a minha mãe Gisele, a minha namorada e companheira Gabriela e a minha avó Ivannette, por todo o amor, carinho, apoio, suporte e torcida, durante essa jornada, tanto nos momentos mais felizes quanto nos mais duros e difíceis.

À Faculdade de Ciências Agronômicas (FCA) da UNESP de Botucatu, por tudo o que me proporcionou durante toda a minha trajetória acadêmica e por todo o aprendizado e conhecimento que adquiri nesses anos, desde a graduação em Engenharia Florestal, o mestrado e agora no doutorado, ambos em Agronomia - Energia na Agricultura.

A todos do Programa de Pós-Graduação em Agronomia – Energia na Agricultura, pela grande oportunidade e honra em cursar o doutorado, em especial aos coordenadores durante esse período, o Prof. Dr. Adriano Wagner Ballarin e Prof. Dr. Marco Antônio Martin Biaggioni.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa de estudos concedida durante o doutorado, sendo de extrema importância para a realização e dedicação exclusiva a este trabalho.

Ao Prof. Dr. Zacarias Xavier de Barros, com quem tive a oportunidade e o prazer de realizar meus estágios docência durante o doutorado, onde aprendi muito sobre a Topografia, dinâmica de aula e como se portar, além de toda a amizade, ensinamentos, convivência e incentivo.

A todos do Departamento de Engenharia Rural da FCA (docentes e colaboradores), em especial na pessoa do Ronaldo Alberto Pollo por toda a ajuda, convivência e ensinamentos durante esses anos.

Aos colaboradores da Seção Técnica de Pós-Graduação por toda ajuda, disposição e esclarecimentos nos momentos de dúvidas

A todos os colaboradores da biblioteca “Prof. Paulo de Carvalho Mattos” do Lageado (FCA/UNESP), pelo excelente e fundamental trabalho, sempre atenciosos, solícitos e dispostos em ajudar e esclarecer dúvidas.

Aos participantes das bancas examinadoras de qualificação e defesa desta tese, Prof. Dra. Yara Manfrin Garcia, Prof. Dr. Osmar Delmanto Júnior, Prof. Dr. Edson

Luís Pirolí e Prof. Dra. Fernanda Leite Ribeiro por todas as correções, sugestões e críticas construtivas propostas, que muito contribuíram para este trabalho.

Aos bons amigos que fiz durante esses anos de Pós-Graduação, seja nas disciplinas, grupos de estudo, no dia-dia, nos momentos de descontração e convivência, esses anos ao lado de todos vocês foram muito especiais e gratificantes, além de toda a troca de conhecimentos, amizade, companheirismo e ajuda: Yara, Mikael, Ana Clara, Bruno, Sara, Samuel, Amanda, Gabriel e Renata.

A todos os colegas e amigos do Grupo de Estudos e Pesquisas em Geotecnologia, Geoprocessamento e Topografia (GEPEGEO) do Departamento de Engenharia Rural da FCA.

A todos os professores que tive o privilégio e felicidade de ter a convivência e assistir aulas no Programa de Pós-Graduação em Agronomia – Energia na Agricultura, que apesar de todas as dificuldades, fazem da nossa ciência um verdadeiro mecanismo de aprendizagem técnico e científico de fundamental importância a todos profissionais desse Brasil.

E enfim, a todos aqueles que não tiveram seus nomes citados ou referenciados, mas que de alguma maneira direta ou indiretamente contribuíram para a elaboração desta tese, a todos vocês minha mais sincera e eterna gratidão!

“As coisas que já imaginei que seriam minhas maiores conquistas, foram só os primeiros passos rumo a um futuro que começo, meramente, a vislumbrar”.

(Jace Beleren - Magic The Gathering® Card Game - Carta “Omnisciense”)

RESUMO

O advento dos drones nas geotecnologias possibilitou uma plataforma atuante em diferentes áreas para o mapeamento com elevada precisão e resolução, como no caso da análise ambiental, onde a correta identificação do uso do solo é de fundamental importância. O objetivo deste estudo consistiu na identificação do uso e ocupação do solo em Áreas de Preservação Permanente (APP) hídricas do rio Lavapés, em trecho da Fazenda Experimental Lageado, no município de Botucatu-SP. Foi utilizada a Análise de Imagem Baseada em Objeto (OBIA), bem como o Índice de Vegetação por Diferença Normalizada (NDVI), e técnicas de aerofotogrametria e fotointerpretação com imagens de alta resolução coletadas por drone. As imagens foram obtidas por meio dos sensores MAPIR Survey3W RGB e Survey3W NIR/InfraRED, embarcados em drone multirrotor 3DR SOLO. Para construção dos ortomosaicos RGB e NDVI, as imagens foram processadas no *software* Pix4Dmapper 3.0. A classificação OBIA RGB obteve acurácia temática por índice Kappa de 70,69 %, com qualidade de classificação "Muito boa" e concordância substantiva com o referencial da VT (Verdade Terrestre). Para a classificação OBIA NDVI, a acurácia temática foi de 73,60 % por índice Kappa, com qualidade de classificação "Muito boa" e concordância substantiva com a VT. A comparação das duas classificações, com a OBIA NDVI como referencial devido a maior acurácia e das propriedades espectrais do NDVI, obteve índice Kappa de 83,16 %, com qualidade de classificação "Excelente" e concordância quase perfeita com o referencial, demonstrando a correlação existente entre uma classificação visual (OBIA RGB) e uma baseada em índice de vegetação (OBIA NDVI). A classe "vegetação arbórea", obteve os menores erros de omissão e comissão nas duas classificações e na comparação entre ambas, garantindo uma grande confiança de classificação. Já a classe "sombras", obteve os maiores erros de omissão e comissão, devido a maior confusão gerada por *pixels* de outras classes, pela ambiguidade espectral e proporcionando menor confiança. Com base no exposto, pode-se afirmar que as imagens obtidas por drone proporcionam flexibilidade de utilização, podendo ser usadas tanto para classificação visual quanto classificação baseada em índice radiométrico, possuindo elevado potencial para o mapeamento da paisagem e comportamento da vegetação e podem ser utilizadas com grande confiabilidade na análise ambiental.

Palavras-chave: Sensoriamento remoto, Veículo Aéreo Não Tripulado, Índice radiométrico, Análise de Imagem Baseada em Objeto.

ABSTRACT

The advent of drones in geotechnologies has enabled a platform acting in different areas for mapping with high precision and resolution, as in the case of environmental analysis, where the correct identification of soil use is of fundamental importance. This study aimed to identify the soil use and occupation in hydric Permanent Preservation Areas (APP) of Lavapés river, in a stretch of Lageado Experimental Farm, located in the municipality of Botucatu-SP. Object Based Image Analysis (OBIA) was used, as well as the Normalized Difference Vegetation Index (NDVI), and techniques of aerophotogrammetry and photointerpretation with high resolution images collected by drone. The images were obtained through MAPIR Survey3W RGB and Survey3W NIR/InfraRED sensors, aboard a 3DR SOLO multirotor drone. For construction of RGB and NDVI orthomosaics, the images were processed using Pix4Dmapper 3.0 software. OBIA RGB classification got thematic accuracy to Kappa coefficient of 70.69 %, with "Very good" classification quality and substantial agreement with VT (Ground Truth) referential. For OBIA NDVI classification, thematic accuracy was 73.60 % to Kappa coefficient, with "Very good" classification quality and substantial agreement with VT. The comparison of the two classifications, with OBIA NDVI as referential due to greater accuracy and spectral properties of NDVI, got Kappa coefficient of 83.16 %, with "Excellent" classification quality and almost perfect agreement with the referential, demonstrating the existing correlation between a visual classification (OBIA RGB) and one based on vegetation index (OBIA NDVI). The "arboreal vegetation" class got the smallest errors of omission and commission in the two classifications and in the comparison between both, guaranteeing a great classification confidence. The "shadows" class got the biggest errors of omission and commission, due to a greater confusion generated by pixels from other classes, through the spectral ambiguity and providing less confidence. Based on the exposed, it can be asserted that images obtained by drone provides flexibility of use, can be used both as a visual classification and as a classification based on radiometric index, having high potential for landscape mapping and vegetation behavior and can be used with great reliability in environmental analysis.

Keywords: Remote sensing, Unmanned Aerial Vehicle, Radiometric index, Object Based Image Analysis.

LISTA DE FIGURAS

Figura 1 – Metragem das APP com base no leito regular dos cursos d'água	37
Figura 2 – Técnicas de sensoriamento remoto para imageamento	41
Figura 3 – Espectro de radiação eletromagnética	42
Figura 4 – Drone de asa fixa e drone multirrotor	54
Figura 5 – Assinatura espectral de objetos na superfície terrestre	57
Figura 6 – Escalas de segmentação de imagens	64
Figura 7 – Exemplo de uma matriz de erros/confusão e seus elementos.....	68
Figura 8 – Localização da área de estudo na Fazenda Experimental Lageado ..	74
Figura 9 – Litologia da área de estudo	75
Figura 10 – Pedologia da área de estudo	77
Figura 11 – Drone quadricóptero 3DR Solo	78
Figura 12 – Sensores MAPIR: Survey3W RGB e Survey3W NIR/InfraRED	79
Figura 13 – Comportamento da pluviosidade no ano de 2018 em Botucatu-SP .	81
Figura 14 – Fluxograma de trabalho	82
Figura 15 – Programação da linha de voo no <i>software Mission Planner</i>	83
Figura 16 – <i>Ground Sample Distance</i> (GSD) de imagens de drone	84
Figura 17 – Pontos de controle GNSS dos ortomosaicos	85
Figura 18 – Sensores acoplados ao drone 3DR Solo	86
Figura 19 – <i>Calibration ground target</i> da MAPIR para calibração de reflectância	89
Figura 20 – Ortomosaicos RGB (A) e infravermelho (B) da área de estudo	96
Figura 21 – Ortomosaico NDVI da área de estudo	98
Figura 22 – <i>Buffer</i> APP em RGB (A) e infravermelho (B) da área de estudo	100
Figura 23 – <i>Buffer</i> APP em NDVI referente à área de estudo	101
Figura 24 – Uso incorreto do solo em APP do rio Lavapés	103
Figura 25 – VT (A) e OBIA RGB (B) da APP da área de estudo	107
Figura 26 – Erros de omissão da matriz VT e OBIA RGB	110
Figura 27 – Erros de comissão da matriz VT e OBIA RGB	112
Figura 28 – VT (A) e OBIA NDVI (B) da APP da área de estudo	114
Figura 29 – Erros de omissão da matriz VT e OBIA NDVI	117
Figura 30 – Erros de comissão da matriz VT e OBIA NDVI	119
Figura 31 – OBIA RGB (A) e OBIA NDVI (B) da APP da área de estudo	122

Figura 32 – Erros de omissão da matriz OBIA RGB e OBIA NDVI	126
Figura 33 – Erros de comissão da matriz OBIA RGB e OBIA NDVI	128

LISTA DE TABELAS

Tabela 1 – Metragem das faixas de APP hídrica na legislação vigente	36
Tabela 2 – Índice Kappa e a sua interpretação e qualidade de classificação	72
Tabela 3 – Parâmetros manipulados no processo de segmentação	92
Tabela 4 – Distribuição de áreas de treinamento e classes OBIA	93
Tabela 5 – Valores de NDVI da área de estudo e sua representatividade	99
Tabela 6 – Valores de NDVI da APP e sua representatividade	102
Tabela 7 – Análise das classes de uso do solo da VT e OBIA RGB	106
Tabela 8 – Matriz de confusão entre VT e OBIA RGB	108
Tabela 9 – Análise das classes de uso do solo da VT e OBIA NDVI	113
Tabela 10 – Matriz de confusão entre VT e OBIA NDVI	115
Tabela 11 – Análise das classes de uso do solo da OBIA RGB e OBIA NDVI	121
Tabela 12 – Matriz de confusão entre OBIA RGB e OBIA NDVI	123

LISTA DE EQUAÇÕES

Equação 1 – Exatidão global	69
Equação 2 – Erro de omissão	69
Equação 3 – Erro de comissão	69
Equação 4 – Índice Kappa	71
Equação 5 – Teste Z	73
Equação 6 – Variância de Kappa pelo método delta	73
Equação 7 – Área de recobrimento	83
Equação 8 – <i>Ground Sample Distance</i>	85
Equação 9 – Índice de Vegetação por Diferença Normalizada	88

LISTA DE ABREVIATURAS E SIGLAS

ANAC	Agência Nacional de Aviação Civil
APAR	Radiação Fotossinteticamente Absorvida
APP	Área(s) de Preservação Permanente
CGIS	<i>Canadian Geographical Information System</i>
DOS	<i>Dark Object Subtraction</i>
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ESRI	<i>Environmental Systems Research Institute</i>
FAA	<i>Federal Aviation Administration</i>
FCA	Faculdade de Ciências Agrônomicas
FMVZ	Faculdade de Medicina Veterinária e Zootecnia
GNSS	<i>Global Navigation Satellite System</i>
GPS	<i>Global Positioning System</i>
GRIB	<i>Gridded Binary</i>
GSD	<i>Ground Sample Distance</i>
HALE	<i>High Altitude Long Endurance</i>
IAF	Índice de Área Foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
IMU	<i>Inertial Measurement Unit</i>
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
IPT	Instituto de Pesquisas Tecnológicas do Estado de São Paulo
IS	Instrução Suplementar
JPEG	<i>Joint Photographics Experts Group</i>
LVd	Latossolo Vermelho Distrófico
LVd ₁	Latossolo Vermelho Distroférico
MALE	<i>Medium Altitude Long Endurance</i>
MRE	<i>Medium Range Endurance</i>
NDVI	Índice de Vegetação por Diferença Normalizada
NIR	<i>Near Infra Red</i>
NVd ₁	Nitossolo Vermelho Distrófico
NVd ₂	Nitossolo Vermelho Distrófico transição Latossolo Vermelho Distrófico

OBIA	<i>Object Based Image Analysis</i>
RBAC-E	Regulamento Brasileiro da Aviação Civil Especial
REM	Radiação Eletromagnética
RGB	<i>Red, Green and Blue</i>
RLd	Neossolo Litólico Distrófico
RPA	Aeronaves Remotamente Pilotadas
RPAS	<i>Remotely Piloted Aerial Systems</i>
RTK	<i>Real Time Kinematic</i>
RYbd	Neossolo Flúvico Distrófico
SAVI	<i>Soil Adjusted Vegetation Index</i>
SIG	Sistema de Informação Geográfica
SIGRH	Sistema Estadual de Gerenciamento de Recursos Hídricos
SISANT	Sistema de Aeronaves não Tripuladas
SMAGIC	<i>Segmentation of Map Guided Ice Classification</i>
SP	Estado de São Paulo
SPRING	Sistema de Processamento de Informações Georreferenciadas
UAS	<i>Unmanned Aircraft System</i>
UAV	<i>Unmanned Aerial Vehicle</i>
UGRHI	Unidade de Gerenciamento de Recursos Hídricos
UTM	Universal Transversa de Mercator
VANT	Veículo Aéreo Não Tripulado
VT	Verdade Terrestre

LISTA DE SÍMBOLOS

m	Metros
nº	Número
2D	Segunda dimensão
3D	Terceira dimensão
µm	Micrômetros
%	Porcentagem
EG	Exatidão global
A	Acerto geral
N'	Número de pontos
EO _i	Erro de omissão
X _{ij}	Observação na linha i e coluna j
X _{ii}	Observação na linha i
EC _j	Erro de comissão
X _{jj}	Observação na coluna j
-	Subtração
+	Soma
K	Coeficiente Kappa
N	Número de observações
r	Número de linhas da matriz
x _{i+}	Total marginal da linha i
x _{+i}	Total marginal da coluna i
<	Menor
>	Maior
=	Igual
≠	Diferente
Z	Teste estatístico Z
var (K)	Variância de Kappa
km	Quilômetros
°	Grau
'	Minutos
"	Segundos

W	Oeste
Gr.	Meridiano de Greenwich
S	Sul
ha	Hectares
°C	Graus Celsius
mm	Milímetros
km ²	Quilômetros quadrados
cm	Centímetros
m/s	Metros por segundo
km/h	Quilômetros por hora
Ac	Área coberta
Av	Altura de voo
Df	Distância focal
Ls	Largura do sensor
Cs	Comprimento do sensor
x	Multiplicação
/	Divisão
ρ'	Tamanho do <i>pixel</i>
Hg	Altura de voo
F	Distância focal
ρ_{NIR}	Refletância do infravermelho próximo
ρ_{RED}	Refletância do vermelho visível
m ²	Metros quadrados
$\geq$	Maior ou igual
α	Nível de significância

SUMÁRIO

1	INTRODUÇÃO	29
2	REVISÃO DE LITERATURA	32
2.1	Legislação ambiental brasileira	32
2.2	Áreas de Preservação Permanente (APP)	34
2.3	Uso e ocupação do solo	38
2.4	Sensoriamento remoto	40
2.5	Sistemas de Informações Geográficas (SIG)	45
2.5.1	<i>Software</i> ArcGIS	47
2.5.2	<i>Software</i> SPRING	48
2.5.3	<i>Software</i> Pix4Dmapper	50
2.6	Veículos Aéreos Não Tripulados (VANTs/Drones)	51
2.7	Índices de vegetação	56
2.8	Classificação de imagens de alta resolução	59
2.9	Análise de Imagem Baseada em Objetos (OBIA)	62
2.10	Acurácia de mapeamentos	66
2.10.1	Matriz de confusão	67
2.10.2	Índice Kappa	70
3	MATERIAL E MÉTODOS	74
3.1	Materiais	74
3.1.1	Caracterização da área de estudo	74
3.1.2	Drone e plataforma de operação	78
3.1.3	Equipamentos e <i>softwares</i> utilizados	79
3.1.4	Dados meteorológicos	80
3.2	Métodos	82
3.2.1	Procedimentos adotados	82
3.2.2	Programação de voo	82
3.2.3	Georreferenciamento e ortomosaicos retificados	85
3.2.4	Índice de Vegetação por Diferença Normalizada (NDVI)	87
3.2.5	Calibração da reflectância dos mosaicos RGB e NIR/InfraRED	88

3.2.6	Processo de segmentação e classificação OBIA	90
3.2.7	Validação estatística das classificações	93
4	RESULTADOS E DISCUSSÃO	96
4.1	Ortomosaicos retificados	96
4.2	NDVI como instrumento no diagnóstico ambiental	97
4.3	Análise das APP da área de estudo	100
4.4	Análise da segmentação e classificação OBIA	104
4.4.1	Comparação entre VT e OBIA RGB e validação	105
4.4.2	Comparação entre VT e OBIA NDVI e validação	113
4.4.3	Comparação entre OBIA RGB e OBIA NDVI e validação	121
5	CONCLUSÕES	133
	REFERÊNCIAS	135

1 INTRODUÇÃO

As Áreas de Preservação Permanente (APP) são zonas compostas por formações de vegetação nativa e de ocorrência natural, que possuem função ambiental relacionada à proteção, como no caso de áreas com declividade superior a 45°, topos de morros, margens de corpos d'água e nascentes de mananciais (vegetação ripária), existentes tanto em áreas rurais quanto urbanas e são amparadas pela legislação florestal brasileira (Lei nº 12.651, com as modificações da Lei nº 12.727, ambas de 2012).

As APP hídricas são consideradas aquelas referentes as margens de sistemas hidrográficos e nascentes, possuem funções hidrológicas, ecológicas e limnológicas de mantenedoras desses recursos, por meio de sua vegetação ciliar, que age como uma barreira física protegendo de agentes externos como sedimentos, erosão e enxurrada. Por isso, a correta identificação dessas áreas e saber se estão íntegras ou com outra utilização ou cobertura sobre o solo é de grande valia para a análise da situação florestal e ambiental de dada localidade.

Para a correta identificação da cobertura do solo é necessário ter o auxílio de ferramentas capazes de realizar esse tipo análise de forma eficaz, dentre essas ferramentas destaca-se a utilização do sensoriamento remoto, que permite avaliar e monitorar importantes fatores relacionados ao meio ambiente, bem como a interação das atividades antrópicas com o mesmo.

Por meio de técnicas oriundas do sensoriamento remoto fica possível a obtenção de um conjunto de informações sobre um determinado alvo, sem necessariamente ter de entrar em contato direto com o mesmo, com a utilização de sensores, que podem estar acoplados em satélites, aeronaves e em Veículos Aéreos Não Tripulados (VANTs/Drones), sendo este último aclamado como a mais recente inovação referente as geotecnologias, após a criação do sistema Global Positioning System (GPS).

Comparado com outros tipos de plataformas no campo da fotogrametria os drones possuem como principal vantagem a sua logística referente a expansão na resolução temporal e flexibilidade na atualização de dados, apesar da baixa

cobertura de área, se comparado com fotografia aérea e imagens de satélite. Porém, a diminuição de custos que tal tecnologia proporciona na obtenção de produtos com elevada resolução espacial e com valor agregado maior, viabilizando projetos principalmente de cunho acadêmico no ramo de mapeamento ambiental.

Uma metodologia empregada amplamente, como forma de monitoramento ambiental e estudos dos usos e ocupação do solo de um determinado local é por meio de índices radiométricos ou índices de vegetação. Os índices são elaborados a partir do comportamento espectral de alvos bióticos e abióticos, que representam as atividades dos mesmos. O Índice de Vegetação por Diferença Normalizada (NDVI), corresponde então a razão referente a diferença entre as refletividades das faixas do infravermelho próximo e do vermelho visível, pela soma das refletividades dos mesmos comprimentos de onda.

Com o advento dos drones atuando nas mais diversificadas áreas, como no caso da análise ambiental, onde a correta identificação do uso do solo é fundamental, passa-se dessa forma a ter uma plataforma para imageamento e mapeamento com elevada precisão e resolução. Dessa forma, este estudo pretende aliar a recente tecnologia de drones para a coleta de fotografias aéreas com o índice radiométrico NDVI, para a obtenção da utilização do solo mais próxima do real, esclarecendo as potencialidades dessa recente geotecnologia, reduzindo o tempo na aquisição de dados com precisão confiável e homogênea e servindo de base para futuros projetos na temática de conservação e preservação ambiental, podendo ser dimensionada conforme as necessidades e características específicas de cada área.

O objetivo geral deste estudo consistiu na identificação e caracterização do uso e ocupação do solo na APP hídrica do rio Lavapés em um trecho dentro dos limites da Fazenda Experimental Lageado, localizada no município de Botucatu, estado de São Paulo, com a utilização do índice radiométrico NDVI e da classificação baseada na técnica de segmentação da Análise de Imagem Baseada em Objeto (*Object Based Image Analysis* - OBIA) por meio de aerofotogrametria fazendo-se uso de drone.

Os objetivos específicos desta pesquisa foram:

- 1) Construir um banco de dados geográficos em ambiente de Sistema de Informação Geográfica (SIG) para a identificação e classificação das zonas de APP, com informações adquiridas a campo por meio de aerofotogrametria e aerofotointerpretação das imagens com alta resolução espacial obtidas por drone;
- 2) Identificar e mapear a zona de APP utilizando-se do índice radiométrico NDVI e da classificação OBIA;
- 3) Obter a verdade terrestre da zona de APP com base no ortomosaico na faixa do visível (RGB);
- 4) Realizar a classificação segmentada baseada em objeto do ortomosaico em RGB da APP e cruzar com os resultados da verdade terrestre como método de validação;
- 5) Realizar a classificação segmentada baseada em objeto do ortomosaico em NDVI da APP e cruzar com os resultados da verdade terrestre como método de validação;
- 6) Comparar as duas classificações (RGB e NDVI), fazendo-se uso das respostas espectrais obtidas dos alvos bióticos e abióticos para quantificar a precisão da técnica empregada;
- 7) Calibrar e aperfeiçoar as técnicas de sensoriamento remoto empregadas em imagens de alta resolução espacial coletadas por drone como ferramentas práticas e confiáveis para a análise de informações ambientais.

2 REVISÃO DE LITERATURA

2.1 Legislação ambiental brasileira

A legislação ambiental brasileira é considerada a nível mundial como uma das mais completas e complexas, o seu embasamento está em concordância com a importância da temática ambiental nas últimas décadas, uma vez que essa questão referente ao meio ambiente é amplamente discutida a nível global, devido à sua importância na qualidade de vida do homem e demais seres vivos (GARCIA, 2011).

O Código Florestal brasileiro, constitui-se como sendo uma legislação de ordenamento jurídico referente à proteção florestal, com caráter conservacionista em relação ao uso sustentável dos recursos naturais. Entretanto, a falta de fiscalização e o não cumprimento das leis, tornaram necessário que certas mudanças fossem realizadas na legislação ao longo dos anos, principalmente em favorecimento ao setor do agronegócio nacional (GONÇALVES, 2016).

As leis ambientais do Brasil procuram suprir as demandas de um país em franco desenvolvimento em diversos setores da economia, principalmente, o agronegócio, causando a expansão das fronteiras agrícolas. Dessa maneira, a conservação dos recursos florestais, bem como a criação de leis e limitações para sua exploração, estabelece uma percepção mais antropocêntrica em relação a proteção da vida e das atividades produtivas, de forma a garantir a perpetuidade e a sustentabilidade do meio (SILVA et al., 2011).

Apenas em meados dos anos 30 é que uma legislação própria para as florestas foi criada, por meio do primeiro Código Florestal brasileiro, que foi aprovado pelo Decreto nº 23.793 de 23 de janeiro de 1934, durante o governo Vargas (GARCIA, 2017). Porém só em 1965 é que se teve uma atualização nessa legislação, que ficou conhecida na época como novo Código Florestal Brasileiro, com a criação da Lei Federal nº 4.771 de 15 de setembro de 1965. Onde houve uma maior preocupação em relação a preservação e conservação dos recursos hídricos, com áreas consideradas como sendo de risco, dessa forma, as Florestas Protetoras passaram a ser as Áreas de Preservação Permanente (GARCIA, 2011).

Já na Constituição Federal de 1988, foi abordado de maneira mais abrangente a temática ambiental e reserva à União, Estados, Distrito Federal e municípios a tarefa de proteger o meio ambiente (GARCIA, 2017). Esta refletiu amplamente de forma positiva para o debate da temática ambiental no Brasil, uma vez que nessa legislação a conservação dos recursos ambientais está intimamente relacionada com o processo de desenvolvimento econômico e social, legitimando de forma legal a gestão da água, determinando dessa maneira, o regime jurídico e legal referente aos recursos hídricos e as competências legislativas e administrativas das unidades da federação (RIBEIRO, 2012).

A legislação florestal brasileira sofreu inúmeras mudanças ao longo dos últimos anos, sendo a última delas ocorrida em 2012, porém, apenas no intervalo de tempo entre 1965 a 2012, sofreu um total de 83 modificações, oriundas principalmente da necessidade e de interesses políticos, a fim de sanar certas brechas ou criar mais limitações, por meio de medidas provisórias (GARCIA, 2014). A Lei nº 12.651, de 25 de maio de 2012, foi proposta originalmente como sendo a legislação florestal brasileira definitiva, porém, ao longo do seu processo de “reforma” sofreu diversas mudanças, inicialmente por meio de medidas provisórias e, por fim, em outubro de 2012, pela Lei nº 12.727 (ZAKIA; PINTO, 2013).

A lei florestal (Lei nº 12.727), sancionada em 17 de outubro de 2012, alterou a Lei nº 12.651, de 25 de maio de 2012, que dispõe sobre a proteção da vegetação nativa, estabelecendo normas gerais sobre a proteção da vegetação, Áreas de Preservação Permanente e as áreas de Reserva Legal; a exploração florestal; o controle da origem dos produtos florestais e o controle e prevenção dos incêndios florestais, sendo um compromisso do país com a preservação das suas florestas e demais formas de vegetação nativa, bem como da biodiversidade, solo, e dos recursos hídricos.

Nessa atualização da lei florestal, para as APP em propriedades rurais e no entorno de corpos d'água, os conceitos se mantiveram os mesmos, somente alterando a partir de onde começa o leito regular do rio. O conceito de Reserva Legal também foi mantido. Também houve a regulamentação do Cadastro Ambiental Rural (CAR), que passou a ser obrigatório para todos os proprietários de imóveis rurais, para que os mesmos possam ter acesso os benefícios do governo. Outro

ponto modificado, foi com relação às áreas rurais consolidadas em APP, que passaram a ser permitidas, unicamente, para a continuidade de atividades agrossilvipastoris, ecoturismo e turismo rural em áreas rurais consolidadas até a data de 22 de julho de 2008.

As mudanças na legislação florestal são fundamentadas em planos do governo para a criação de um cadastro para o monitoramento ambiental, com a finalidade de combater o desmatamento de áreas florestais e nas demais fitofisionomias nativas do Brasil. Dessa forma, a nova legislação busca amparar e corrigir as falhas e brechas nas legislações anteriores, permitindo teoricamente um melhor planejamento ambiental das propriedades rurais (GONÇALVES, 2016).

Tendo esses conceitos como base, a abordagem da legislação florestal e das Leis nº 12.651 e nº 12.727 são de grande valia, uma vez que pode ser considerado como o primeiro na abordagem de temas como a gestão ambiental e a sustentabilidade (GARCIA, 2014). Dentre todas as leis ambientais abordadas anteriormente, enfatiza-se que no presente estudo foi utilizada a Lei Florestal, Lei nº 12.651, com as mudanças incluídas pela Lei nº 12.727, ambas de 2012.

2.2 Áreas de Preservação Permanente (APP)

As APP são consideradas como verdadeiros ecossistemas e que possuem grande importância para a manutenção, funcionamento e equilíbrio dos sistemas hídricos. Desta maneira, a legislação brasileira, por meio da Lei Florestal nº 12.727, estabelece em seu Artigo 3º que a APP consiste de um espaço protegido, podendo ter a cobertura ou a ausência da vegetação nativa, a qual deve ser mantida intacta, possuindo uma função ambiental fundamental na proteção de corpos d'água, paisagem, estabilidade geológica e biodiversidade como um todo, além de proporcionar o fluxo gênico da fauna e flora, protegendo o solo e assegurando o bem-estar das populações humanas (BRASIL, 2012b).

No artigo 6º da Lei nº 12.651 são definidas as finalidades e destinação das APP, sendo que suas finalidades implicam em: Conter a erosão do solo e mitigar riscos de enchentes e deslizamentos de terra e de rocha; Proteger as restingas ou

veredas; Proteger várzeas; Abrigar exemplares da fauna ou da flora ameaçados de extinção; Proteger sítios de excepcional beleza ou de valor científico, cultural ou histórico; Formar faixas de proteção ao longo de rodovias e ferrovias; Assegurar condições de bem-estar público; Auxiliar a defesa do território nacional, a critério das autoridades militares; Proteger áreas úmidas, especialmente as de importância internacional (BRASIL, 2012a).

Na atual legislação também se aborda o uso e ocupação em APP, em localidades denominadas como “áreas consolidadas”. Esses usos consistem de atividades agrossilvipastoris, de ecoturismo, de turismo rural e obras de infraestrutura como barracões, instalações, casas de máquina, entre outras, em áreas consolidadas até 22 de julho de 2008 com os proprietários rurais enquadrados nessas utilizações, uma recomposição mínima da vegetação das APP, levando em consideração o tamanho do imóvel rural na referida data (GARCIA, 2014).

Segundo Criado e Piroli (2012), as leis e resoluções que tangem à proteção e conservação das APP são justificadas pela importância ambiental que estas apresentam. Sua fundamentação está relacionada aos principais problemas de degradação do meio ambiente e que estão relacionados às alterações das mesmas, como a intensificação dos processos erosivos, deposição de sedimentos e materiais erodidos e, conseqüentemente, o assoreamento de recursos hídricos, que implicam em problemas em todo o sistema de uma bacia hidrográfica comprometendo a demanda hídrica da mesma.

As características que as APP possuem, denotam que essas não são áreas qualquer, mas sim áreas protegidas, dessa forma, proibindo-se qualquer tipo de utilização ou exploração que por ventura venha a interferir na totalidade do conjunto de características que embasam a sua proteção, e que são áreas protegidas de maneira permanente (MACHADO, 2013).

Para Zakia (2013), as APP podem ainda ser divididas em tipos, que levam em consideração certas características. Podendo essas serem divididas da seguinte forma: “hídrica natural”, vegetação presente ao longo de nascentes, cursos d’água intermitentes ou perenes, lagos, lagoas naturais e veredas; “reservatório”, formações vegetais nas bordaduras de reservatórios d’água artificiais, decorrentes de obras de represamento, barragens, vertedores e obras hidráulicas geralmente construídas em

cursos d'água naturais; “relevo”, zonas vegetadas ao longo de encostas, bordas dos tabuleiros, chapadas, topo de morros, montes, montanhas e serras; “costeira”, a região vegetada da costa marinha, como as restingas e os manguezais.

As APP hídricas são zonas de ocorrência natural ao longo dos corpos d'água, com a presença de formações vegetais, nativas ou não, e que devem ser mantidas inalteradas, com os objetivos de assegurar a conservação dos recursos hídricos, a estabilidade geológica e a biodiversidade, bem como, o bem-estar das populações. A legislação florestal vigente é rígida e permite apenas em casos excepcionais e de extrema utilidade pública a possível supressão de forma parcial da vegetação ciliar (GONÇALVES, 2016).

Outra definição importante que a última legislação florestal trouxe foi a definição da largura de metragem das faixas de APP, levando-se em conta o tamanho (largura) dos cursos d'água perenes e intermitentes desde a margem da calha do leito regular dos mesmos. Na Tabela 1 tem-se um resumo com relação a metragem referente ao tamanho dos corpos d'água e suas respectivas faixas de APP hídrica pela legislação vigente.

Tabela 1 - Metragem das faixas de APP hídrica na legislação vigente.


Largura do curso d'água (m)	Faixa de preservação em cada margem (m)
Até 10	30
Entre 10 e 50	50
Entre 50 e 200	100
Entre 200 e 600	200
Superior a 600	500
Nascentes	Raio de 50

Fonte: Brasil (2012b).

Também é importante ressaltar a correta definição quanto à expressão “leito regular” ou “calha regular” do rio contida na legislação vigente, que expressa o início da demarcação das APP hídricas. Levando-se em consideração o texto da legislação para a delimitação das APP, com o leito regular dos cursos d'água como base, o texto acaba por não levar em consideração fatores importantes como os referentes as variabilidades climáticas (GARCIA, 2014). Na Figura 1, é possível observar a aplicação da metragem da faixa APP hídrica, cujo a vegetação ciliar

localiza-se ao longo do curso d'água, com base na largura do leito regular do mesmo.

Figura 1 - Metragem das APP com base no leito regular dos cursos d'água.



Fonte: CIFlorestas (2019).

É evidente também salientar a importância da presença de vegetação nativa, principalmente, nas zonas de APP, devido a sua importante função ambiental referente ao ciclo hidrológico e controle do microclima da região em que está inserida, controle do escoamento superficial e, conseqüentemente, a atenuação de processos erosivos e proporcionando também, uma qualidade de vida melhor para o homem (GONÇALVES, 2016). Dessa maneira, o papel da vegetação ciliar presente nas APP é de vital importância para a conservação e proteção do meio, devido as suas características protetivas em alusão aos cílios presentes nas pálpebras, atuando como um agente de redução de impactos ambientais.

E apesar da atual legislação brasileira ser considerada como sendo uma das mais avançadas e repressivas com relação a importância das APP, a lacuna existente na fiscalização e a impunidade constituem-se em um incentivo negativo à conservação das mesmas, somando-se a este cenário ainda as investidas contra a

legislação ambiental, tornando-a propícia ao agronegócio e dessa forma, incapaz de cumprir sua função primária de preservação do meio ambiente e ecossistemas (CRIADO; PIROLI, 2012).

As atividades e ações do homem em relação ao meio ambiente aumentam cada vez mais, acelerando o processo de degradação dos recursos naturais, como a supressão da vegetação ciliar nas zonas de APP para à expansão da agricultura, causando grandes danos ao meio, principalmente, devido a processos erosivos que se iniciam pela ausência de vegetação e que desagregam partículas do solo, que pelo efeito da enxurrada das chuvas e da lixiviação acarreta em assoreamento de corpos d'água, e na diminuição da qualidade da água interferindo na demanda hídrica (GARCIA, 2017).

2.3 Uso e ocupação do solo

Para Luchiari et al. (2013), as diferentes formas de mudanças que ocorrem na natureza, levam a transformações fisiográficas dos territórios, alterações essas que sucedem a paisagem, principalmente, por meio da ação antrópica, devido ao uso e ocupação das áreas que o homem explora, deixando traços de sua exploração e levando à extinção de inúmeras espécies de animais e vegetais, dentre outras consequências. Existem diversos motivos que norteiam o caminho do homem para alterar a natureza ou a paisagem ao seu interesse, não apenas pela necessidade de fixação ou existência, mas por outras formas de utilização do meio.

A expressão “uso/ocupação da terra ou do solo”, de acordo com Rosa (1992), consiste na forma com que o homem ocupa o espaço físico, onde é possível avaliar se o espaço é explorado de forma sustentável mantendo uma mínima qualidade ambiental, ou seja, de forma ordenada, produtiva e com o mínimo de impactos causados ao ambiente.

As dinâmicas de utilização do solo, estão intimamente relacionadas as atividades socioeconômicas de uma região e, por consequência, acabam por refletir o desenvolvimento de pesquisas e tecnologias e as relações de ligação entre a sociedade e a natureza, além de demonstrar o grau de conservação, preservação e

degradação dos recursos naturais em contrapartida aos diversos setores de produção (SANTOS; SOUZA, 2011).

O levantamento do uso e ocupação do solo permite avaliar as modificações provocadas ao meio pelo homem e fornece um conjunto de informações que são cruciais para a gestão dos recursos naturais. Esse conjunto de informações obtidas, podem revelar o grau de conservação, preservação ou até mesmo a artificialização, o quão ela foi modificada pelo homem em uma dada área (VIERA; ROVANI, 2009).

Pesquisas referentes à utilização da cobertura do solo proporcionam informações relevantes referentes a alterações temporais ocorridas, principalmente, no que tange as áreas com mudanças na paisagem, onde a vegetação nativa é substituída por práticas agrossilvipastoris, para o avanço da fronteira agrícola. Dessa forma, essas mudanças afetam negativamente a paisagem, solo e água, podendo causar também outros tipos de danos ambientais ao sistema (ZANATA, 2014).

Ainda, o uso inadequado do solo de forma desordenada pode dar origem a processos de perda de solo, compactação, aumento nas quantidades de sais no solo e conseqüentemente a lixiviação de resíduos e partículas, causando o assoreamento e deposição de resíduos em cursos d'água e por fim, perdas em termos tanto qualitativos quanto quantitativos (CUNHA; RITTER; BORBA, 2014).

O solo quando utilizado de forma inadequada causa diversos tipos de problemas ambientais em bacias hidrográficas, podendo trazer prejuízos de grande escala para o próprio solo, para a vegetação e para a população ao entorno, contribuindo dessa forma, com a diminuição do nível socioeconômico em pequenas propriedades rurais (SANTOS, 2009).

De acordo com Lepsch (2010), na elaboração de seu “Manual do Uso da Terra”, a humanidade é dependente dos recursos fornecidos pelo meio e que a cercam, a exemplo do ar, a água e os solos agricultáveis. Contudo, o homem nem sempre utiliza os recursos naturais que tem disponíveis de forma sustentável para preservá-los.

A utilização e a cobertura que o solo possui, se tornou um tema amplamente debatido e estudado nas últimas décadas nos mais diversos níveis do conhecimento, devido principalmente aos diversos tipos de problemas relativos ao

meio ambiente e referentes ao uso e ocupação de maneira desordenada. Para Araújo, Teles e Lago (2009), as ações desenfreadas ligadas à sua utilização, constituem um dos grandes desafios a serem enfrentados pelas políticas de controle ambiental.

Segundo Montebelo et al. (2005), os estudos referentes a utilização da terra, despertam interesses em todas as frações da sociedade. Além de monitorar e acompanhar possíveis impactos no meio ambiente pode-se também acompanhar o grau de desenvolvimento socioeconômico de uma dada localidade, em escala local, regional e até global, inclusive para efeito de comparação entre regiões com características semelhantes.

De uma forma geral, por meio do conhecimento e sabendo-se dos padrões de utilização da terra, é possível identificar os tipos e as necessidades de cada área, a fim de garantir a sustentabilidade, que engloba o tripé entre o social, o ambiental e o econômico. Os tipos de uso podem ser espacializados, caracterizados e quantificados, obtendo-se assim dados que demonstram não somente a atual situação, mas também todo o histórico. (IBGE, 2013).

O desenvolvimento e o avanço de geotecnologias como o sensoriamento remoto permitem o acesso a uma variada gama de ferramentas que podem auxiliar no monitoramento e fiscalização das dinâmicas de ocupação do solo, sendo aplicáveis a gestão ambiental e à coleta de informações, tanto em níveis regionais quanto municipais (CATELANI; BATISTA; PEREIRA, 2003).

2.4 Sensoriamento remoto

O sensoriamento remoto possui sua origem vinculada ao surgimento das primeiras aerofotos ou fotografias aéreas, dessa maneira, seu histórico é dividido em dois momentos distintos: o primeiro, entre o período de 1860 a 1960, onde constituiu-se única e exclusivamente a utilização de fotografias aéreas; e o segundo, de 1960 até aos dias atuais, caracterizado por uma gama variada de formatos de imagens orbitais e sub-orbitais obtidas por sensores ativos (GARCIA, 2014).

A aplicação do sensoriamento remoto e do seu conjunto de técnicas (Figura 2) são possíveis por meio da sequência de algumas etapas do processo que consiste desde a interação em si, caracterizada principalmente pelo fenômeno de reflexão da radiação eletromagnética emitida, a obtenção de informações e, conseqüentemente, o seu registro por meio de um sensor ou conjunto de sensores, o armazenamento dessa informação, e por fim, o posterior processamento dessas informações com o objetivo de extrair o máximo possível de dados presentes e pretendidos de um determinado objeto (PONZONI, 2001).

Figura 2 - Técnicas de sensoriamento remoto para imageamento.



Fonte: Florenzano (2011).

Para Tagliarini (2017), o sensoriamento remoto fundamenta-se na interação entre a radiação eletromagnética (REM) natural emitida pelo Sol ou por uma fonte de energia artificial, captada por sensores embarcados em plataformas orbitais e sub-orbitais, com diferentes objetos localizados na superfície terrestre, dessa maneira, é possível obter-se então um conjunto de dados sobre um determinado alvo, sem a necessidade de entrar em contato direto com o mesmo.


O sensoriamento remoto ainda remete a interação simultânea entre sensores, equipamentos e transmissão de dados, com o objetivo de estudar os acontecimentos da superfície do globo terrestre pelas manifestações e interações da

radiação eletromagnética e das substâncias presentes nas superfícies analisadas (NOVO, 2010).

Dessa forma, é possível obter o registro (imagem) de um alvo, por meio da radiação refletida ou absorvida por alvos presentes na superfície escaneada, sem a existência de contato direto do sensor com o alvo a ser estudado, analisando a partir do comportamento espectral, o que a imagem do objeto em estudo apresenta em cada comprimento de onda obtido (PEREIRA; SILVA; PAMBOUKIAN, 2016).

Já o espectro da luz solar (Figura 3), consiste na distribuição da radiação eletromagnética emitida pelo Sol em função do comprimento de onda, podendo variar desde o raio gama até as ondas de rádio, sendo esta energia, dessa forma, dividida em faixas ou regiões espectrais em termos de frequência e comprimento de ondas (LORENZZETTI, 2015).

Figura 3 - Espectro de radiação eletromagnética.



Fonte: Furian (2014).

Cada alvo a ser estudado possui uma assinatura espectral. Esta assinatura está associada ao comportamento dos objetos da superfície terrestre em relação a radiação eletromagnética que estes estão sujeitos, ou seja, as formações vegetais, culturas, corpos d'água e o solo, por exemplo, absorvem e/ou refletem a radiação

emitida, levando em consideração as suas características bioquímicas e físicas, bem como de acordo as características do comprimento de onda (FLORENZANO, 2011).

Assim, pode-se resumir o sensoriamento remoto como sendo o uso em conjunto de sensores, equipamentos para o armazenamento e o processamento de informações, e os equipamentos para a transmissão das mesmas, embarcados em aeronaves, balões, VANTs/drones, espaçonaves, ou satélites artificiais orbitais com a finalidade de estudar todos os fenômenos que acontecem no globo terrestre (NOVO, 2010).

A principal vantagem do sensoriamento remoto é a sua abrangência para o monitoramento, que pode cobrir áreas grandes a um menor custo, possibilitando também o estudo de mudanças temporais que ocorrem no meio ambiente (BATISTELLA; MORAN, 2008). Shimabukuro, Maeda e Formaggio (2015) afirmam que essa geotecnologia é uma excelente ferramenta para a análise de fatores relacionados com as atividades do homem no ambiente.

O sensoriamento remoto passou a ser utilizado em grande escala durante as últimas décadas por permitir um rápido monitoramento, avaliação de importantes variáveis ambientais e de diversos fatores relacionados com o impacto das atividades do homem no ambiente (SHIMABUKURO; MAEDA; FORMAGGIO, 2015). Essa geotecnologia oferece uma grande potencialidade de utilização para o acompanhamento da utilização do solo de uma determinada localidade, sobretudo nas áreas agrícola e ambiental.

As imagens oriundas do sensoriamento remoto são analisadas e estudadas com base nos elementos presentes e as características que possuem, como: tonalidade, cor, textura (impressão de rugosidade), tamanho, forma, sombra, altura, padrão (arranjo espacial dos objetos), localização e contexto (FLORENZANO, 2008; RODRIGUES, 2016). Um exemplo disso seria a distinção de áreas irrigadas por sistema de pivô central de outros métodos de irrigação, onde baseando-se na geometria da superfície de molhamento é possível distinguir qual método de irrigação seria.

Várias aplicações, que são frutos do sensoriamento remoto podem ser utilizadas tanto no campo da agricultura quanto no do meio ambiente, como por

exemplo, para a previsão de safras, mapeamento de culturas, definição de áreas de aptas para agricultura, zoneamento agroecológico, estudos de perdas de solo, monitoramento de riscos de incêndios florestais, dentre outras finalidades (RODRIGUES, 2015; TAGLIARINI, 2017).

Para Shimabukuro, Maeda e Formaggio (2015), uma das grandes vantagens em se utilizar produtos oriundos do sensoriamento remoto para a análise e reconhecimento da utilização do solo é que as informações podem ser constantemente atualizadas devido à periodicidade e repetitividade para aquisição desses produtos, de uma maneira rápida e com grande confiabilidade, sendo que o conjunto de informações obtidas, importantes para o levantamento, mapeamento e posterior utilização dos dados referentes à utilização da terra de um determinado local.

Rodrigues, Rodrigues e Tagliarini (2014), observaram que os objetos-alvos são detentores de inúmeras características, tanto em corpos de massa líquida (rios, lagos, lagoas, represas e oceanos) quanto em corpos constituídos por massa sólida, como exemplo, os solos e as diferentes formas de vegetação encontradas como florestas, pastagens, lavouras (agroecossistemas), além das áreas urbanas ou antropizadas.

Dessa forma, quanto maior for o conhecimento sobre a área em que se está estudando, maior será o conjunto de dados e informações que podem ser coletados a partir das análises e estudos de imagens de uma determinada área (GARCIA, 2017).

Nesse contexto, para Rosa (2009), a utilização e análise de produtos oriundos de sensoriamento remoto são de grande importância para estudos das mudanças nas dinâmicas de utilização da cobertura da terra. Sendo o emprego destes tipos de informações muito amplo e de grande valia dentro do planejamento e diagnóstico de impactos causados por atividades de cunho exploratório em relação ao meio ambiente (TAGLIARINI, 2017).

Dessa maneira, a utilização das técnicas de sensoriamento remoto para análises referentes a paisagem do meio, colaboram e possibilitam a coleta e a manipulação de informações com grande confiabilidade e de forma rápida, para a

tomada de decisões, auxiliando nos reconhecimentos ao nível de campo e fiscalização da legislação florestal vigente (GONÇALVES, 2016).

2.5 Sistemas de Informações Geográficas (SIG)

O Sistema de Informação Geográfica (SIG), traduzido do acrônimo original em inglês *Geographic Information System* (GIS) consiste em um conjunto de ferramentas oriundas de um *hardware* ou *software*, que são utilizadas para o geoprocessamento (TAGLIARINI, 2017).

O desenvolvimento do primeiro SIG é recente, com origem no Canadá, na década de 1960 com o CGIS (*Canadian Geographical Information System*) e desenvolvido por Roger Tomlinson. O desenvolvimento dessa ferramenta, ocorreu com o apoio do governo canadense com a finalidade de implementar um levantamento referente aos recursos naturais do país (ABREU, 2012; GARCIA, 2017).

Já no Brasil, o primeiro SIG teve seu desenvolvimento estruturado em 1982, com a participação direta do pesquisador Roger Tomlinson, sendo que após a sua visita ao país, grupos de estudos e pesquisas nacionais foram criados com o intuito de desenvolvimento e propagação do advento dos SIGs em território nacional (GARCIA, 2014).

Os SIGs em si consistem em um conjunto de *softwares* para computadores, o qual integra dados, equipamentos e pessoas com a finalidade de coletar, armazenar, recuperar, manipular, visualizar e analisar dados obtidos e espacialmente referenciados a um dado plano de coordenadas conhecido (FITZ, 2008). O SIG ainda é considerado, como uma ferramenta extremamente eficaz dentro do conjunto de geotecnologias que competem ao geoprocessamento, possibilitando diferentes práticas de sensoriamento remoto como: fotogrametria, fotointerpretação, topografia, cartografia, modelagem de dados geoestatística, entre outras (FLORENZANO, 2011).

O ambiente do SIG, consiste basicamente no trabalho com dois tipos de informações geográficas que são os vetores e as matrizes (*rasters*), e que se destacam por sua capacidade analítica.

Os vetores consistem em pontos, linhas (dois pontos interligados) e polígonos (conjunto de pontos e linhas), e são compreendidos por conjuntos de coordenadas: eixo X (leste-oeste), eixo Y (norte-sul) e Z (altitude), esses tipos de informações permitem modelagem em duas ou três dimensões e cálculos geométricos. Os dados matriciais ou *rasters* representam o espaço por meio de *pixels* (malha contínua), sendo os mesmos identificados por meio de linhas e colunas, dessa forma, os *pixels* registram valor numérico unitário e que correspondem a dados e informações de objetos presentes e em processo de análise (RODRIGUES, 2015).

Ao se iniciar qualquer tipo de análise espacial em ambiente SIG, deve-se atentar a ocorrência de uma conversão da “paisagem real” e observada para uma “paisagem digital”, para então uma posterior visualização e armazenagem das informações coletadas, determinado um conjunto de finalidades (FERREIRA, 2007). Dessa forma, o SIG possibilita um banco de dados, com informações oriundas do meio físico, de dados censitários, de cadastramentos urbanos e rurais, e de diferentes origens de informações como as imagens de satélites e coordenadas de GPS (CASANOVA et al., 2005).

O SIG não se restringe apenas a conversão, armazenamento e manipulação de dados, tendo evoluído ao ponto de permitir ao usuário trabalhar as interações espaciais entre as informações coletadas, permitindo a elaboração de diversas formas de analisar, propor cenários, diagnósticos e modelagem (MOURA, 2014). O SIG ainda consiste como sendo o principal mecanismo de apoio a análise, a gestão, o manejo e a tomada de decisão de informações passíveis de serem geoespacializadas (ABREU, 2012).

A constante evolução dos *softwares* SIG, proporcionou aos estudos da temática ambiental, técnicas cada vez mais precisas, com aplicações cada vez mais elaboradas. O homem passou a ter a seu alcance tecnologias que possibilitaram um grande avanço na produção e elaboração de mapas. Dessa forma, trabalhos que anteriormente eram feitos de forma manual, agora são elaborados digitalmente, assim, os mapas passaram a ter maior exatidão cartográfica e um alto grau de

qualidade, sendo confeccionados em um período de tempo menor, obtendo esse grande diferencial em relação as metodologias mais tradicionais de mapeamento (FREITAS FILHO, 2004).

O surgimento e a constante evolução dos computadores contribuíram para o grande crescimento referente à utilização de SIGs para os mais diversos fins, principalmente na década de 1980. Já no início da década de 1990, muitas empresas do ramo das geotecnologias se consolidaram e se estabeleceram, comercializando *softwares* SIG, com destaque para a ESRI com o ArcGIS, a Autodesk com o AutoCAD Map, o ERDAS, MapInfo, ENVI e TerrSet (antigo IDRISI), que são exemplos de *softwares* comerciais e com licença paga. Por sua vez, também tem os *softwares* de licença livre e abertos, como o SPRING, QGIS, ILWIS, gvSIG, GRASS GIS e SAGA GIS (RISTOW, 2014).

2.5.1 Software ArcGIS

O ArcGIS consiste em um pacote integrado de *softwares* SIG desenvolvido pela empresa norte-americana *Environmental Systems Research Institute* (ESRI), tendo a sua primeira versão denominada ArcView 1.0, lançada no ano de 1992. Desde o final da década de 1990, o ArcGIS se consolidou como uma referência no mercado das geotecnologias, fornecendo ferramentas baseadas em padrões para a armazenagem e manipulação de informações, análise espacial, processamento de dados geográficos e mapeamentos (SILVA; MACHADO, 2010).

O *software* ArcGIS disponibiliza um ambiente SIG, com uma grande variedade de ferramentas que de maneira integrada proporcionam uma utilização bem prática e simples. A base do ArcGIS consiste em um conjunto de ferramentas sofisticadas, que servem para o processamento, criação, edição, manipulação, gerenciamento, análise, exibição e saída de informações geográficas (PEGORARO; BONETTI; GERMANO, 2014).

O SIG ArcGIS é um sistema de partes que podem ser implementadas em um único computador ou *notebook*, ou em uma rede interligada de computadores e servidores. Dessa maneira, os seus usuários podem utilizar várias partes deste

sistema que o *software* proporciona para elaborar um SIG para usuários individuais, grupos de pesquisa, departamentos, grandes empreendimentos, entre outras finalidades (REIS, 2016).

Este SIG é um dos mais utilizados mundialmente por apresentar uma ampla variedade de extensões e ferramentas, além da capacidade de leitura de diversos tipos de arquivos de diferentes formatos, reconhecendo importantes tipos de extensões utilizadas nas plataformas de geoprocessamento como, por exemplo, *shapefile*, extensão própria do ArcGIS, extensões do AutoCAD (.dwg, .dxf, .dgn), .TIFF, .GEOTIFF, .JPEG, .BMP, GRID e DEM, dentre outros tipos de arquivos (SILVA; MACHADO, 2010).

A sua aplicabilidade na análise de superfícies inclui a topologia das informações, áreas de influência (*buffers*), análise de proximidade, busca lógica e espacial, modelagem de rede e de dados matriciais (*rasters*), além de análises tabulares (PEGORARO; BONETTI; GERMANO, 2014).

O ArcGIS usa modelos de dados para representar a geografia terrestre de forma digital e provê todas as ferramentas necessárias para poder manejar e manipular dados geográficos. Isto inclui ferramentas para todas as tarefas de SIG: edição e automatização dados, mapeamento cartográfico tarefas, análises geográficas, administração de dados avançados e desenvolvimento de dados e aplicações na Internet, entre outras (REIS, 2016).

O ArcGIS está basicamente dividido em três aplicativos que são: o ArcMap, o ArcCatalog e o ArcToolbox. O ArcMap, permite a exibição de informações espaciais, criação de mapas em camadas (*layers*) e realizar análises espaciais básicas, também possui ferramentas padrões avançadas para manipulação de vetores (*shapefile*) e bancos de dados (*geodatabase*). O ArcCatalog, fornece ferramentas para a exploração, armazenamento, pesquisa e gerenciamento das informações. Já o ArcToolbox, contém muitas ferramentas utilizadas para o geoprocessamento (*geoprocessing*) de dados e operações mais elaboradas com dados geográficos (SILVA; MACHADO, 2010; REIS, 2016).

2.5.2 Software SPRING

O SPRING, acrônimo de Sistema de Processamento de Informações Georreferenciadas, consiste em um *software* nacional do tipo SIG, desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE), tendo o seu desenvolvimento iniciado em 1991, com a sua primeira versão oficial lançada em abril de 1994 (CÂMARA et al., 1996).

Por ser um *software* de licença livre e aberto, o SPRING é considerado como de domínio público, podendo ser adquirido de forma gratuita, diretamente do site do INPE. Dessa forma, o *software* SPRING torna-se uma interessante alternativa aos *softwares* pagos, dentro do conjunto de SIGs disponíveis no mercado, sendo divulgado e utilizado em diversas pesquisas nacionais e internacionais (ECKHARDT et al., 2007).

A criação do SPRING teve como premissa base os seguintes objetivos: a construção de um SIG para utilização nas mais diversas áreas como agricultura, floresta, gestão ambiental, geografia, geologia, planejamento urbano e regional; ser um *software* acessível para todos, além de ser um SIG de aprendizado fácil; proporcionar em um ambiente unificado de geoprocessamento para as mais diversas aplicações; e por fim, ser um mecanismo de difusão do conhecimento desenvolvido pelo INPE e seus parceiros, sob forma de novos algoritmos e metodologias (INPE, 1991).

O *software* SPRING é um SIG no estado-da-arte com funções de processamento de imagens, análise espacial, modelagem numérica de terreno e consulta a bancos de dados espaciais (INPE, 1991). Apresentando ainda um conjunto de ferramentas voltadas à coleta e tratamento de informações espaciais, além de gerar saídas na forma de mapas convencionais, relatórios, arquivos digitais, e outros, devendo prover recursos para armazenamento, gerenciamento, manipulação e análise de dados (ECKHARDT et al., 2007).

O SPRING é um *software* composto basicamente por três módulos e um aplicativo auxiliar, que são: SPRING, IMPIMA, SCARTA e IPLOT. O módulo SPRING consiste em um banco de dados geográfico para ambientes Windows e UNIX, esse sistema administra tanto dados vetoriais como *rasters* e permite a

integração das informações obtidos. O módulo IMPIMA tem a função de converter os diversos tipos de arquivos para a extensão .grb, um formato compactado de dados GRIB (*GRIdded Binary*). Já o módulo SCARTA, consiste em um editor de mapas que faz a interligação com o módulo SPRING, por meio do banco de dados, dessa forma, SCARTA altera as informações em análise. E por fim, o IPLOT é um aplicativo auxiliar ao SIG e que possui interface com o ambiente Windows com a função de exportar e imprimir os mapas gerados no módulo SCARTA (RÖHM et al., 2003).

2.5.3 Software Pix4Dmapper

O Pix4Dmapper consiste em um *software* SIG voltado especificamente para a aerofotogrametria e aerofotointerpretação de dados obtidos por *Remotely Piloted Aerial Systems* - RPAS ou drones, voltados para a modelação digital e produção de informações geográficas em geral, desenvolvido pela empresa suíça Pix4D, que iniciou suas atividades no segmento das geotecnologias no ano de 2011 (MOUTINHO et al., 2015).

O Pix4Dmapper é um *software* referência no processamento de imagens digitais obtidas por drones, obtendo informações nos planos 2D e 3D georreferenciados e com alta precisão como: ortomosaicos, modelos digitais de elevação, nuvens de pontos em 3D, modelos 3D texturizados e geração de vídeos de apresentação desses modelos, informações de áreas, volumes, dentre outras funcionalidades (SANTIAGO & CINTRA, 2019).

Esse *software* opera em três linhas, sendo uma para *desktop*, uma para compartilhamento em nuvem e outra para plataformas móveis. Dessa forma, o Pix4Dmapper permite que o processamento das informações seja contínuo e o mais otimizado possível, possibilitando trabalhar os dados obtidos desde forma online e compartilhada por nuvem, até a tradicional no próprio computador, sem depender do acesso à internet para o processamento dos dados (PIX4D, 2020).

O funcionamento da fotogrametria do Pix4Dmapper parte do princípio da conversão das imagens obtidas por drone em três produtos, a nuvem de pontos 3D,

o modelo digital de elevação em 3D e os ortomosaicos retificados. Assim, o *software* por meio da ferramenta *RayCloud*, começa identificando pontos chaves nas imagens causadas pelas sobreposições das mesmas, resultando em uma posição triangulada de pontos chaves em um espaço 3D, que por sua vez gera um ponto na nuvem de pontos 3D em um sistema de coordenadas cartesiano (HAWKINS, 2016).

O Pix4Dmapper ainda por meio de sua ferramenta de *Raster Calculator*, permite a geração de mapas de índices a partir de fórmulas pré-definidas ou por fórmulas personalizadas criadas pelos usuários. Com isso, o *software* possibilita a geração de mapas de refletância precisos do objeto de interesse; ortomosaicos de índices de vegetação, com o cálculo por diferentes bandas; geração de modelo digital da superfície (MDS), possibilitando o cálculo de volumes (SANTIAGO & CINTRA, 2019; PIX4D, 2020).

Com relação aos ortomosaicos, o *software* Pix4Dmapper consegue converter os arquivos gerados para outros tipos de extensões como .kml extensão referente ao *software* Google Earth Pro, e .GEOTIFF possibilitando, dessa forma, a exportação dos ortomosaicos retificados e georreferenciados para outros *softwares* SIG. Além disso, o *software* ainda conta com um Editor de Mosaico, para possíveis alterações em regiões do mesmo que necessitam de alguma correção (MOUTINHO et al., 2015; HAWKINS, 2016).

Levando em conta as suas aplicações, o Pix4Dmapper possibilita a sua utilização por profissionais de diversos mercados como: topografia, mineração, indústrias, agricultura, floresta, meio ambiente e outras áreas que trabalham com mapeamento de imagens com alta resolução (SANTIAGO & CINTRA, 2019; PIX4D, 2020).

2.6 Veículos Aéreos Não Tripulados (VANTs/Drones)

O histórico da aviação, semelhante a outros adventos tecnológicos que são empregados no cotidiano de forma corriqueira, é decorrente dos avanços tecnológicos que surgiram nos períodos de confrontos bélicos na história da humanidade. Semelhante ao que ocorreu com o GPS, os Veículos Aéreos Não

Tripulados (VANT's) surgiram inicialmente para o mercado militar e com o propósito de utilização em confrontos bélicos. Os estudos dessa tecnologia iniciaram logo após o final da segunda guerra mundial, nos Estados Unidos, sendo que os primeiros registros referentes a utilização desta tecnologia em combates foram na guerra do Vale do Bekaa em 1982, onde Israel utilizando-se de dois modelos de drones realizou bombardeios na área (SILVA NETO, 2015).

No ano de 2006, na Universidade de Ciência e Tecnologia de Hong Kong, foi fundada por Frank Wang a *DJI Technology*, considerada hoje como uma das empresas líderes no segmento mundial de VANTs comerciais e acessíveis ao público em geral. Apesar de empresas comerciais já existirem desde o ano de 2002 nos EUA, somente no ano de 2015, que ocorreu a exigência do congresso americano sobre a regulamentação da administração de aviação civil pela *Federal Aviation Administration* (FAA), que os VANTs foram inseridos oficialmente no espaço aéreo americano. A partir deste momento, o termo “drone” tornou-se popular e houve a grande disseminação pelo mercado (RAKHA; GORODETSKY, 2018).

A Instrução Suplementar (IS Nº 21-002A), homologada pela Agência Nacional de Aviação Civil (ANAC), de outubro de 2012, define os VANTs como sendo aeronaves projetadas para operar sem piloto a bordo, que possui uma carga útil embarcada e que não seja utilizado para fins meramente recreativos. Nesta definição incluem-se todos os aviões, helicópteros e dirigíveis controláveis nos três eixos, excluindo-se, portanto, os balões tradicionais e aeromodelos (ANAC, 2012).

A partir de 3 de maio de 2017, pela Resolução nº 419, de 2 de maio de 2017, entrou em vigor o Regulamento Brasileiro da Aviação Civil Especial nº94 (RBAC-E nº94/2017) homologado pela ANAC, o qual estabelece os requisitos gerais de competência da ANAC para aeronaves não tripuladas de uso civil (ANAC, 2017). Após um ano da regulamentação, mais de 40000 drones já haviam sido cadastrados no Sistema de Aeronaves não Tripuladas (SISANT), gerenciados pela própria ANAC (ANAC, 2018).

Por esse novo regulamento, fica definido que aeromodelos são as aeronaves não tripuladas remotamente pilotadas usadas para recreação e lazer e as aeronaves remotamente pilotadas (RPA) são as aeronaves não tripuladas utilizadas para outros fins como experimentais, comerciais ou institucionais. Só podendo ser operados em

áreas com no mínimo 30 m horizontais de distância de pessoas não anuentes ou não envolvidas com a operação e cada piloto remoto só poderá operar um equipamento por vez. Aeronaves não tripuladas com peso máximo de decolagem (incluindo-se o peso do equipamento, bateria e de eventual carga) de até 250 gramas não precisam ser cadastradas no SISANT junto à ANAC, já as aeronaves operadas em linha de visada de até 120 m acima do nível do solo devem ser cadastradas e, nesses casos, o piloto remoto deverá possuir licença e habilitação (ANAC, 2017).

Enfatiza-se que no recorte do presente estudo, foi seguida a legislação vigente do órgão responsável (ANAC) para aeronaves não tripuladas de uso civil (Resolução nº 419, de 2017), para o imageamento e mapeamento utilizando-se de drone.

De acordo com Silva (2013), a nomenclatura portuguesa de VANT corresponde à terminologia em inglês *Unmanned Aerial Vehicle* (UAV) intitulada pelo Departamento de Defesa Norte Americano (*U. S. Department of Defense*). Porém, a nomenclatura ideal para essas aeronaves encontra-se em um debate constante, a FAA utiliza o termo *Unmanned Aircraft System* (UAS) que serve tanto para designar a aeronave em si, quanto o conjunto da aeronave mais os elementos embarcados e/ou em associação com a mesma, como por exemplo, a estação de controle, equipamentos de navegação, sensores entre outros tipos de equipamentos necessários para a operação do drone.

Já o termo “drone”, é uma terminologia empregada popularmente e difundida comercialmente em todo o mundo para designar aos veículos aéreos não tripulados, sendo originado nos Estados Unidos da América, que em uma tradução livre para a língua portuguesa significa literalmente “zangão”, nomenclatura essa devido ao som emitido pelos rotores do equipamento quando ligado e em voo, sendo semelhante ao zumbido de abelhas e zangões.

Com relação à classificação e categorização dessas aeronaves, cada país desenvolve seu conjunto de regras e normas próprias para agrupar os drones em diferentes categorias, resultando em diversos tipos de classificações. A Associação Internacional (*UVS International*) de drones adota a classificação por certas características dos drones como alcance, altura de voo, autonomia em horas e peso

para agrupar os drones nas seguintes categorias: *Mini*, que corresponde a alcance inferior a 10 km e autonomia de voo de até duas horas; *Medium Range Endurance* (MRE), possuem alcance acima de 500 km e autonomia de voo de 10 a 18 horas; *Medium Altitude Long Endurance* (MALE), com uma altitude de 5 a 8 mil m e autonomia de voo entre 24 a 48 horas; e *High Altitude Long Endurance* (HALE), que possuem altitude superior a 20 mil m e autonomia de voo que varia entre 24 a 48 horas (BLYENBURGH, 2010; SILVA, 2013).

No Brasil, também existe um sistema de classificação e enquadramento para os drones, mas esses são geralmente divididos com relação ao seu tamanho e/ou porte em três grupos, que são: pequeno, médio e grande porte. Porém, essa classificação pode gerar outras divisões diferentes, uma vez que um mesmo drone pode ser enquadrado em mais de uma categoria, dependendo de qual variável que está sendo analisada e considerada para o enquadramento (SILVA, 2013).

Outra forma de classificar esses equipamentos é com relação ao seu sistema de propulsão para o voo (Figura 4), podendo ser divididos dessa maneira em duas categorias, os drones de asa fixa e os drones multirrotores.

Figura 4 - Drone de asa fixa e drone multirrotor.



Fonte: Gomes (2019).

Os drones de asa fixa necessitam de impulso ou tomada de distância, tendo até equipamentos próprios, como catapultas, para a sua decolagem, mas que podem fazer a cobertura de grandes áreas, pois sua bateria é mais econômica o que proporciona maior estabilidade e autonomia durante o voo. Já os drones

multirrotores apresentam um sistema de hélices propulsoras em suas asas e que podem decolar sem a necessidade de qualquer impulso, no próprio local em que estão pousados, operam em velocidades mais baixas que os drones de asa fixa, podendo até ficar estáticos em pleno voo, porém possuem uma menor autonomia de voo, devido a sua bateria, que possui uma duração média entre 24 a 27 minutos dependendo principalmente do conteúdo de peso embarcado no drone (KNEIPP, 2018).

Com relação ao emprego dos drones no mercado, esses possuem uma grande diversidade de áreas de atuação desde recreativas (lazer), militar, construção civil, na agricultura, monitoramento ambiental, jornalismo, publicidade entre outros. O mercado dos drones está em ampla expansão, demonstrando-se como sendo uma das novas geotecnologias a serem exploradas. As mais variadas aplicações, bem como os diferentes modelos, podem ser empregues seguindo adaptações referentes à demanda exigida por diferentes profissionais em suas regiões de atuação (SILVA, 2013).

Os drones ao serem comparados a outras plataformas sub-orbitais e até mesmo orbitais, como a fotogrametria obtida por coleta de informações via aviões e satélites, possuem certas vantagens, conforme destacado por Honkavaara et al. (2013), que analisaram a capacidade dos drones em coletar informações com elevada resolução espacial e com resolução temporal desejada.

Os drones possuem como vantagem em relação a outras técnicas convencionais de sensoriamento remoto, a obtenção de produtos com elevada resolução espacial, de forma rápida e contínua, inclusive em tempo nublado que dificulta a obtenção de imagens por outros sensores. Essa é uma grande vantagem dos Drones em relação a utilização de imagens de satélites, principalmente na agricultura, pois os satélites que possuem resolução temporal diária, geralmente também possuem uma baixa resolução espacial e os de elevada resolução espacial, geralmente possuem periodicidade maior, além de serem pagos, algo que pode vir a impossibilitar o monitoramento constante das culturas (JIN-KI; JONGHWA, 2015).

O custo benefício acaba por ser uma variável atrativa, pois os drones apresentam excelente relação entre custo e benefício, quando relacionados com outras plataformas de imageamento. Tamminga et al. (2015) destacam que o baixo

custo, alta performance, flexibilidade de operação e a resolução espacial centimétrica, além da facilidade no processamento e análise das informações espaciais obtidas, estando diretamente relacionados com sistema de trabalho e a interface dos *softwares* para o tratamento e análise de imagens disponíveis no mercado.

Devido as características apresentadas anteriormente, os drones possuem potencial de empregabilidade e de mercado bem grande, sobretudo nas áreas agrônômica e ambiental, possibilitando a obtenção de imagens e outros produtos de sensoriamento remoto com alta qualidade, velocidade e precisão. Sua utilização ao invés de outras técnicas de imageamento irá depender das características da região de análise, da periodicidade para a obtenção de informações e do valor monetário do equipamento, dessa forma, ficando a critério do responsável pelo levantamento qual técnica de sensoriamento remoto melhor aplicar.

2.7 Índices de vegetação


Os índices de vegetação consistem em uma técnica elaborada e empregada de maneira global como forma de monitorar e estudar as formações vegetais de uma dada localidade. De acordo com Jensen (2009), os índices são medidas radiométricas adimensionais obtidas do comportamento espectral da vegetação, que indicam a atividade fotossintética da vegetação, porcentagem de cobertura vegetal, teor de clorofila em plantas, acúmulo de biomassa, estágio de desenvolvimento, entre outras características. Além dessas características os índices permitem ainda avaliar e estudar o estado fisiológico e fenológico de culturas, estresse hídrico e vigor de vegetações, bem como detecção de mudanças tanto naturais como antrópicas na paisagem.

Os pigmentos fotossintetizantes presentes nas folhas dos vegetais, absorvem a radiação solar causando a baixa reflectância das folhas na região do visível, enquanto que as estruturas celulares provocam uma alta reflectância no espectro do infravermelho. Este comportamento espectral das plantas é o que os índices de vegetação demonstram e exploram, os quais correspondem aos parâmetros

biológicos, fisiológicos e químico das formações vegetais (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Dentro do sensoriamento remoto, os índices radiométricos podem ser empregados como uma ferramenta auxiliar para a detecção e o reconhecimento da cobertura vegetal, possibilitando o seu destaque por meio de suas características espectrais, dessa forma, proporcionando uma melhor distinção em relação aos outros elementos presentes na paisagem. Para essa finalidade, utiliza-se radiação eletromagnética, bem como a assinatura espectral dos objetos (Figura 5), bem como, cálculos tendo como base as respostas das refletâncias dos mesmos nas diferentes regiões do espectro (LIU, 2007).

Figura 5 - Assinatura espectral de objetos na superfície terrestre.



Fonte: Florenzano (2011).

Muitos dos índices de vegetação foram desenvolvidos pela combinação de duas ou mais bandas referentes a diferentes comprimentos de onda, utilizadas em modelos matemáticos para analisar diversas características das culturas agrícolas. Esta combinação de diferentes espectros, proporcionam uma maior sensibilidade na interpretação de informações espectrais adquiridas por sensores, facilitando o uso

desse produto oriundo de sensoriamento remoto e o transformando em uma importante ferramenta para a agricultura (UNO et al., 2005).

O Índice de Vegetação por Diferença Normalizada (NDVI) consiste na razão entre a diferença das refletividades das bandas do infravermelho próximo e do vermelho, pela soma dessas mesmas refletividades (ROUSE et al., 1973). O uso dessas bandas se dá por conta da absorção da clorofila, que ocorre próximo ao comprimento de onda de 0,67 μm (GAO, 1996).

O NDVI é capaz de quantificar e atribuir valores de -1 a 1 para a vegetação e outros corpos presentes na análise (BORATTO; GOMIDE, 2013). Sendo a faixa próxima de -1 a 0, correspondente a corpos d'água, solos expostos e construções (áreas impermeabilizadas), enquanto que valores superiores a 0 até 1 indicam vegetação com diversificados valores de vigor e diferentes estágios de desenvolvimento. De acordo com Melo, Sales e Oliveira (2011), quanto mais próximo do valor 1, maior o grau de desenvolvimento e de atividade fotossintética pela vegetação, dessa maneira, destaca que a cobertura vegetal da área está em um estágio vigoroso.

O NDVI é um índice muito utilizado como ferramenta para o monitoramento de perfis sazonais e temporais de atividades agrícolas e florestais. Estes perfis são muito utilizados para analisar em diferentes cultivos a longevidade do período de desenvolvimento, maturação, floração, frutificação e colheita, bem como, dos momentos de intervenções no manejo devido a mudanças no comportamento espectral dessas plantas (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Por utilizar os espectros referentes ao vermelho e do infravermelho próximo, o NDVI acaba por ser um índice sensível a mudanças que ocorrem durante todo o estágio de crescimento e durante todo o ciclo de desenvolvimento das formações vegetais, dessa forma, o NDVI é utilizado para a caracterização de parâmetros tanto quantitativos quanto qualitativos referentes a cobertura vegetal de uma dada região, como, por exemplo, o emprego desse índice para a estimação de produção de uma cultura, na identificação de estágio de desenvolvimento de formações vegetais, na detecção de radiação fotossinteticamente absorvida pelas plantas, dentre outras finalidades (BASTIAANSEN; MOLDEN; MAKIN, 2000).

Além da capacidade de indicar o vigor vegetativo e o teor de água encontrado na cobertura vegetal, o NDVI também pode contribuir na identificação pluviométrica de uma determinada região, auxiliando nas características hídricas da superfície, sendo intimamente correlacionados (LEIVAS et al., 2013).

O NDVI, além de outros índices radiométricos como o *Soil Adjusted Vegetation Index* (SAVI) e o Índice de Área Foliar (IAF) são utilizados constantemente para a estimativa e o cálculo dos componentes referentes ao balanço hídrico das plantas, como a radiação e a evapotranspiração, pois a partir desses também pode-se inferir sobre as condições fisiológicas da vegetação e, conseqüentemente, correlacionar com outros parâmetros, como no caso da estimativa da radiação fotossinteticamente absorvida, da produtividade de culturas e no cálculo da emissividade da superfície (BASTIAANSSEN; MOLDEN; MAKIN, 2000).

O NDVI também é utilizado extensivamente para o monitoramento de ecossistemas, pois consegue medir as mudanças na quantidade de clorofila presente na vegetação, principalmente, na identificação e quantificação de secas, onde valores baixos de NDVI, próximos a 0 representam menor vigor e capacidade fotossintética da vegetação, o que é característico da vegetação de regiões em estiagem (YINGXIN et al., 2007).

2.8 Classificação de imagens de alta resolução

A classificação de imagens digitais multiespectrais é responsável pela criação de mapas temáticos, que consiste na subdivisão em rótulos ou classes que indicam objetos reais identificados nas mesmas. O primeiro passo para a rotulagem de imagens digitais, baseia-se na identificação das categorias as quais os objetos reais pertencem, tais como florestas, culturas, pastagens, corpos d'água, entre outros. Já o segundo passo consiste na rotulagem numérica das entidades (*pixel*, ou segmento, ou objeto) a serem classificadas (SCHOWENGERDT, 2007). No entanto, deve-se determinar anteriormente o número e natureza das categorias, onde a

cobertura de utilização da terra é descrita com base na rotulagem dos objetos estabelecidos (MASTELLA; VIEIRA, 2018).

O processo de classificação pode ser então enquadrado, de forma genérica, como sendo um processo que consiste em agrupar os *pixels* referentes a um objeto de estudo em classes pré-estabelecidas pelo próprio usuário (JENSEN, 2015). Nesse contexto, as imagens digitais dotadas de elevada resolução espacial são empregadas cada vez mais para obter o máximo possível de informações referentes ao meio físico por meio de diferentes metodologias para a classificação e rotulação das mesmas (GONZALEZ; WOODS, 2011).

As duas formas de abordagens utilizadas para treinar e rotular *pixels* são conhecidas na literatura como classificação supervisionada e classificação não-supervisionada. No processo de classificação supervisionada, o observador define as amostras de treinamento previamente e, dessa forma, o valor referente ao comportamento espectral dos *pixels* naquele ponto, assim o algoritmo empregado classifica todos os *pixels* ou objetos conforme regras de decisão (SCHOWENGERDT, 2007). Já o processo de classificação não-supervisionada é reconhecido pelo seu caráter exploratório, dessa maneira, o próprio computador identifica o conjunto de *pixels* ou objetos dentro de uma classe, utilizando-se de algoritmos e não sendo necessário o conhecimento prévio dos tipos de utilização da terra encontrados nas imagens (SCHOWENGERDT, 2007; GABRIEL, 2013; MASTELLA; VIEIRA, 2018).

Com a constante evolução das geotecnologias, fica possível a análise mais eficiente dos ambientes, onde novas técnicas permitem seu reconhecimento e, por meios do classificador orientado a objeto, que utiliza o princípio da segmentação com intuito de homogeneizar as informações e que facilita a análise da imagem (SILVA et al., 2016).

A segmentação consiste em um processo de divisão das imagens em segmentos homogêneos. Essa técnica tem sido comumente empregada em imagens digitais com elevada resolução espacial, principalmente em áreas urbanas, onde o grau de detalhamento é maior (GONZALEZ; WOODS, 2011; SILVA et al., 2016).

As metodologias mais usuais para o processo de classificação de imagens, consistem em agrupar os *pixels* em classes, utilizando-se como base a análise das características espectrais denominada “*pixel por pixel*”, essas classificações possuem uma alta variância intraclasse e comporta-se como ruídos durante o processo em imagens de alta resolução, ocasionando em problemas nos resultados da classificação (ALENCAR-SILVA; MAILLARD, 2009).

Uma das alternativas quando se trabalha com imagens de elevada resolução espacial é incorporar como classificação, metodologias que empreguem além da resposta espectral referente a cada *pixel*, também características relacionadas com distribuição espacial dos objetos identificados nas imagens. Esta metodologia é denominada como análise de imagem baseada em objeto e o seu processamento consiste em basicamente duas partes que são: o processo de segmentação da imagem, tendo base em parâmetros já pré-estabelecidos; e a rotulagem das classes obtidas no processo, com as identificações das utilizações do solo (N-BARBOSA; ACCO; KIRCHNER, 2003).

A análise de imagem baseada em objeto consiste no estudo da relação presente entre um objeto com os outros objetos ao seu redor, dessa forma, o objeto acaba por ser o elemento da imagem que é dotado das características espaciais, os quais podem se agregar a outros objetos ou a um conjunto de objetos, resultando em diferentes escalas de segmentação (ANTUNES; STURM, 2005).

O fundamento que envolve o processo de orientação a objeto, se embasa em características intrínsecas dos próprios objetos, que podem ser observadas, respectivamente, com base na geometria dos mesmos, que compreende a topologia, a forma e a posição, além dos temáticos, que consistem nas características não espaciais referentes aos objetos (ANTUNES; LINGNAU; CENTENO, 2003).

O conceito de objeto no processo de segmentação, define que um segmento deve seguir os contornos de um objeto real, sendo esta considerada como uma situação ideal. Dessa maneira, os parâmetros do processo de segmentação devem ser minimamente aceitáveis de acordo com o problema. Em testes realizados com produtos detentores de moderada resolução espacial, é possível verificar que os

segmentos obtidos se mostram menores do que os objetos reais analisados (BAATZ; SCHÄPE, 2001; STURM et al., 2003)

O processo de orientação baseado em objeto é eficaz para a segmentação de imagens de alta resolução, pois não considera apenas o *digital number* do *pixel* analisado, mas também o referente aos *pixels* em seu entorno, buscando por similaridades estatísticas, dessa maneira, agrupando os *pixels* em conjuntos de semelhantes (PARANHOS FILHO; LASTORIA; TORRES, 2008). Contudo, Antunes, Lingnau e Centeno (2003) discorrem que essa é apenas uma das alternativas para se distinguir alvos que não podem ser separados meramente com informações espectrais, pois a classificação orientada a objeto leva também em consideração informações adicionais de forma e textura dos mesmos.

Dentre os principais segmentadores de imagens, pode-se destacar, por exemplo, o *Segmentation of Map Guided Ice Classification* (SMAGIC) e o eCognition, que além da classificação automática em imagens digitais com elevada resolução espacial, esse tipo de *software* também permite que o analista faça a classificação das imagens de maneira totalmente visual, o que permite a aplicação da fotointerpretação baseada na resposta espectral, pois o *software* faz o processamento do *pixel* com base no seu contexto e não de maneira isolada, reconhecendo assim os agrupamentos de *pixels* como sendo diferentes objetos na imagem (SILVA et al., 2016).

2.9 Análise de imagem baseada em objetos (OBIA)

O método denominado como análise de imagem baseada em objeto (*Object Based Image Analysis* - OBIA) foi desenvolvido a partir de pesquisas realizadas na Alemanha e Áustria com o objetivo de encontrar uma forma de classificação mais adaptada as imagens de alta resolução espacial, um novo padrão o qual o sensoriamento remoto passou a encontrar, principalmente após os anos 2000 marcada pelo lançamento de satélites e sensores capacitados à aquisição de dados com alta resolução espacial (WHITESIDE; AHMAD, 2005; MENESES; ALMEIDA, 2012; FURTADO; FRANCISCO; ALMEIDA, 2013). A grande maioria das

metodologias mais usuais que são empregadas para a análise de imagens digitais consiste em *pixels* e na resposta espectral destes e possuem como base parâmetros estatísticos que são extraídos de elementos amostrais para a classificação.

O uso de objetos ou segmentos, que são extraídos de imagens por meio de *pixels* homogêneos permite que a análise possa extrapolar os dados provenientes de agrupamentos de *pixels*, e assim inserir novas formas de análise e classificação fundamentadas na geometria, conjunção e hierarquia dos objetos analisados. Em estudos em que o objetivo é o isolamento de alvos naturais, a similaridade encontrada em grupamentos de *pixel* com um mesmo valor, torna-se um padrão com características triviais, uma vez que feições de vegetação abrangem uma quantidade significativa de *pixels* homogêneos (RODRIGUES et al., 2016).

A concepção em si dos objetos comporta a determinação de propriedades baseadas nos mesmos, como por exemplo, atributos estatísticos, textura, forma, topologia e semântica, podendo-se utilizar dessa maneira de diferentes níveis de segmentação (FRANCISCO; ALMEIDA, 2013). Portanto, um primeiro agrupamento de *pixel* ou objetos adjacentes é unificado em novos objetos baseados no crescimento de regiões (SILVA JUNIOR; FRANK; RODRIGUES, 2014).


A segmentação de imagens digitais então consiste na subdivisão das mesmas em objetos constituídos por agrupamentos de *pixels* adjacentes que são segmentados com base em suas características intrínsecas (WHITESIDE; AHMAD, 2005; LUZ; ANTUNES; TAVARES JÚNIOR, 2010). Portanto, cada segmento corresponde a uma região na imagem formada pelo conjunto de *pixels* homogêneos em uma ou mais dimensões do espaço de atributo (BLASCHKE, 2010; SILVA JUNIOR; FRANK; RODRIGUES, 2014).

A segmentação minimiza o efeito conhecido como *salt and pepper* (sal e pimenta), que consiste na existência de pequenos polígonos dispersos pela imagem ao longo da área a ser mapeada. Este efeito requisita operações de análise de contexto espacial e a utilização de filtros para a remoção de ruídos e imperfeições na imagem (MENESES; ALMEIDA, 2012; RODRIGUES, 2015).

Na segmentação as imagens então sofrem uma divisão em regiões de menores dimensões e de tamanho uniforme, utilizando-se de um algoritmo para o

crescimento de regiões (Figura 6). O parâmetro de escala adotado, acaba limitando o tamanho do segmento (STURM et al., 2003). Um balanço entre o formato dos segmentos e a sua uniformidade espectral acaba por ser o responsável pelo crescimento direcionado dos mesmos. Sendo a sua forma, avaliada de acordo com parâmetros intrínsecos dos próprios objetos como a compacidade e suavidade.

Figura 6 - Escalas de segmentação de imagens.



Fonte: Mountrakis, Im e Ogole (2011).

Dessa forma, para se utilizar da OBIA é preciso, primeiramente, gerar os objetos. Os parâmetros de manipulação para segmentar uma imagem podem ser o número de bandas e o tamanho da janela de varredura, que se desloca pela imagem analisando a similaridade espectral e avaliando a variância presente (MASTELLA; VIEIRA, 2018). Outros parâmetros como a média e o desvio padrão, e a similaridade permitida/tolerada entre segmentos (quanto maior for o valor desta similaridade, menor é o número de segmentos) também podem ser utilizados (GABRIEL, 2013; JENSEN, 2015).

A imagem sofre a influência de parâmetros como a similaridade, a cor e a compacidade. O algoritmo de segmentação pode ser configurado com base nas características das imagens utilizadas no processo, por meio desses três parâmetros. A similaridade, medida que está relacionada com a heterogeneidade dos *pixels* definindo o tamanho dos objetos; a cor, consiste no equilíbrio da homogeneidade das cores dos segmentos com a homogeneidade da figura, dessa maneira, valores baixos implicam em um maior peso na utilização desse parâmetro, que é relacionada com as características espectrais da imagem; e a compacidade, parâmetro que consiste no equilíbrio entre a suavidade da borda de um segmento e a sua forma, assim, um valor baixo de compacidade gera objetos mais alongados e com bordas suaves, enquanto que valores altos acarretam em objetos mais compactos e de menores proporções (BAATZ; SCHÄPE, 2001; LUZ; ANTUNES; TAVARES JÚNIOR, 2010).

Para o processo de segmentação necessita-se antes especificar o número de bandas ou comprimentos de onda da imagem, em seguida as mesmas são ponderadas conforme cada um dos seus padrões. Com relação a janela de varredura, indica a variância da imagem, Eastman (2009) sugere que uma janela de varredura de 3x3 *pixels* proporciona melhores resultados.

Com relação aos pesos para o fator médio da variância, esses são utilizados para avaliar a similaridade presente entre os segmentos vizinhos. Por fim, a similaridade de tolerância é usada para controlar o nível de generalização na classificação, os valores de similaridade consistem em uma sequência de números que começam em 0 (zero), indicando o início da partição dos limites de cada uma das regiões (MASTELLA; VIEIRA, 2018).

Whiteside e Ahmad (2005), em estudo empregando a análise de imagem baseada em objeto para a detecção da utilização do solo em área localizada no norte da Austrália obtiveram bons resultados na escala de segmentação com parâmetro de escala 10 (dez), fator de forma 0.4, densidade 0.7, e suavidade, 0.3. Já Jensen (2015), afirma que um fator de escala de segmentação com um valor de 20 (vinte) foi o melhor para criação de objetos, além de que o fator tonalidade foi mais importante que a forma e o equilíbrio entre a suavidade das bordas dos segmentos e a sua compacidade no processo de segmentação.

Neves (2013), em estudo com a classificação da ocupação do solo na região metropolitana de Lisboa, Portugal, utilizando-se da análise de imagem baseada em objetos, testou vários níveis de tolerância de similaridade, variando de 1 (um) a 10 (dez), e afirma que o nível 4 (quatro) foi o que obteve uma melhor escala de segmentação das imagens. O processo que envolve a análise de imagens digitais por segmentação é essencialmente empírico, ou seja, por tentativa e erro, sendo ajustável aos diferentes tipos de imagens e levando-se em consideração a complexidade dos alvos analisados (ANTUNES; LINGNAU; CENTENO, 2003; JENSEN, 2015).

2.10 Acurácia de mapeamentos

O emprego de um sistema robusto para a classificação de imagens é de fundamental importância para garantir a confiabilidade da análise e a acurácia temática da mesma. A acurácia de um mapeamento está relacionada com diversos parâmetros, porém dois deles se destacam com uma importância maior, que são o nível de detalhamento e os esquemas de classificação, além da variabilidade das categorias a serem mapeadas e da verdade terrestre (MENESES; ALMEIDA, 2012; CONGALTON; GREEN, 2019).

Dessa maneira, no processamento das informações obtidas por sensoriamento remoto, uma etapa essencial consiste na avaliação da precisão temática, que possibilita o entendimento da confiabilidade dos dados provenientes de mapas temáticos, provenientes de classificações ou interpolações oriundas de observações espaciais (VIEIRA, 2000).

Para se obter uma boa avaliação da acurácia temática dos produtos de sensoriamento remoto, são necessárias três etapas, que são: o modelo ou esquema de amostragem; modelo de resposta, onde se utiliza da melhor regra de decisão; e a estimativa e análise da acurácia temática, que consiste em índices derivados da matriz de confusão (STEHMAN; CZAPLEWSKI, 1998).

A acurácia temática consiste então na verificação para constatar se o mapa está correto no tocante ao rótulo das classes, além de garantir a qualidade das

informações presentes no mapa, detectando e proporcionando a correção das fontes de erros, assim a avaliação da acurácia determina a qualidade do mapa tanto qualitativamente quanto quantitativamente, indicando e mensurando os erros no processo e presentes no mapeamento (CONGALTON; GREEN, 2019).

Uma maneira de se obter a exatidão temática é por meio da matriz de confusão ou matriz de erros, que propicia a derivação de proporções e, consequentemente, a verificação de erros obtidos no processo de delegação dos *pixels* as suas respectivas classes, avaliando-se assim a acurácia presente no mapeamento de forma quantitativa (VIEIRA, 2000; CONGALTON; GREEN, 2019).

A avaliação do processo de alocação dos *pixels*, utilizando-se da matriz de confusão é denominado como exatidão ou acurácia, a qual emprega-se dados estatísticos de concordância, dessa maneira, fazendo-se referência a concordância e omissão entre a quantidade de *pixels* que foram classificados pelo processo de interpolação, com a quantidade de *pixels* presentes na imagem e utilizados como referência para a comparação (PINHEIRO, 2013).

2.10.1 Matriz de confusão

A acurácia é normalmente expressa em proporção por índices que são obtidos por meio do emprego de matrizes de confusão ou de erros, e que expressam a concordância existente entre a classificação e o conjunto de amostras de referência (PINHEIRO, 2013). Dessa forma, matriz de confusão pode ser utilizada como um ponto de início para uma variedade de análises estatísticas descritivas e analíticas (CONGALTON; GREEN, 2019).

A matriz de confusão consiste em uma metodologia bem eficiente, representada no formato de tabela e que permite organizar e analisar os resultados obtidos pela classificação por meio de um determinado algoritmo (GABRIEL, 2013). Dessa maneira, a matriz de confusão compara, classe por classe, a relação encontrada entre as informações referentes à verdade terrestre (mapa de referência), com as informações correspondentes oriundas da classificação empregada e analisada, devido a entrada dupla de dados, permitindo confrontar o

número de *pixels* ou polígonos observados e considerados como sendo corretos, com o mesmo número de *pixels* ou polígonos classificadas (CONGALTON; GREEN, 2019).

Tanto o número de colunas quanto o número de linhas presentes na matriz de confusão, devem ser semelhantes e proporcionais ao número de classes observadas (Figura 7). Convencionalmente, as colunas representam as unidades observadas (referência), enquanto as linhas são referentes à classificação obtida e em análise. A exatidão global, bem como os erros de omissão (exclusão) e de comissão (inclusão), presentes em cada classe observada são encontrados tendo a matriz de confusão como base (PINHEIRO, 2013; CONGALTON; GREEN, 2019).

Figura 7 - Exemplo de uma matriz de erros/confusão e seus elementos.

Classificação	Dados de Referência				$\sum n_{i+}$
	1	2	...	p	
1	x_{11}	x_{12}	...	x_{1p}	x_{1+}
2	x_{21}	x_{22}	...	x_{2p}	x_{2+}
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
p	x_{p1}	x_{p2}	...	x_{pp}	x_{p+}
$\sum n_{+i}$	x_{+1}	x_{+2}	...	x_{+p}	N

Fonte: Pinheiro (2013).

Assim, a matriz de confusão é constituída por um arranjo quadrado entre os números dispostos em linhas e colunas, e que representam o total de unidades amostradas e referentes a uma dada categoria, seja ela obtida por meio de um classificador ou por uma regra de decisão, relacionada com a classe mais atual e examinada a nível de campo. Já a diagonal principal da matriz de confusão consiste nos valores de concordância referente as informações do referencial (verdade terrestre) e as informações classificadas de maneira acertada (MASTELLA; VIEIRA, 2018; CONGALTON; GREEN, 2019).

Como medidas derivadas da matriz de confusão é possível encontrar a exatidão global, os erros de omissão e comissão, a precisão de classe individual, a

confiança do produtor, a confiança do usuário, entre outros. Por exemplo, uma acurácia de 100 %, indica que todos os *pixels* presentes na imagem ou na amostra foram classificados de maneira acertada em relação a verdade terrestre utilizada; já uma acurácia de 50 %, indica que metade dos *pixels* foram classificados de forma correta na análise (PINHEIRO, 2013).

A exatidão global obtida por meio da matriz de confusão relaciona todos os elementos presentes na diagonal principal com a quantidade total de pontos amostrados, dessa forma, a exatidão global (Equação 1) consiste na somatória dos valores presentes na diagonal principal, divididos pela quantidade total de amostras analisadas, sendo calculada conforme Bishop, Fienberg e Holland (1975).

$$EG = \frac{A}{N'} \times 100 \quad (1)$$

Onde: EG é a exatidão global; A é o acerto geral (pontos amostrais com acerto); e N' é o número de pontos amostrais.

As células marginais nas linhas indicam o número de *pixels* que não foram incluídos em determinada categoria e expressam o erro conhecido por omissão (Equação 2), o qual representa uma definição incorreta da categoria em análise. Já as células presentes nas diagonais das colunas representam os *pixels* que também não foram incluídos em nenhuma categoria, expressando o erro de comissão (Equação 3), o qual determina uma delimitação de forma excessiva referente à categoria que está em análise (CHUVIECCO, 1995; FERREIRA; DANTAS; MORAIS, 2007). Os dois tipos de erros podem ser calculados conforme o proposto por Chuviecco (1995).

$$EO_i = \frac{\sum X_{ij} - x_{ii}}{\sum X_{ij}} \quad (2)$$

Onde: EO_i é o erro de omissão; $\sum X_{ij} - x_{ii}$ é a soma dos resíduos por linha; e $\sum X_{ij}$ é a marginal da linha.

$$EC_j = \frac{\sum X_{ij} - x_{jj}}{\sum X_{ij}} \quad (3)$$

Onde: EC_j é o erro de comissão; $\sum X_{ij} - x_{jj}$ é a soma dos resíduos por coluna; e $\sum X_{ij}$ é a marginal da coluna.

A representação em porcentagem do erro de omissão é denominada como risco do usuário, enquanto que os acertos correspondem a confiança do usuário. Já a representação em porcentagem do erro de comissão é denominada como risco do produtor e os acertos correspondem a confiança do produtor (QUEIROZ et al., 2017).

A análise comparativa da acurácia específica local, na matriz de confusão, pode fornecer métodos mais eficientes e com produtos mais elaborados para comparar a precisão de mapeamentos, ao invés de uma singela comparação de acurácia via exatidão global. Dessa maneira, para determinados casos em que se necessita de uma análise de acurácia mais específica e refinada, é importante a utilização de outros índices estatísticos derivados da matriz de confusão e que utilizam todos os elementos presentes na mesma, como por exemplo, o índice Kappa, o índice Tau, o teste Z estatístico, dentre outros índices e coeficientes de análise (SERRA; PONS, 2008; CONGALTON; GREEN, 2019).

2.10.2 Índice Kappa

O índice Kappa mede o grau de concordância presente em escalas nominais assumindo que todas as unidades em amostra são independentes, e que as classes ou categorias da escala nominal também são independentes e mutuamente exclusivas, bem como o classificador e os pontos considerados como referência, que operam de maneira independente (COHEN, 1960).

O Kappa é expresso por meio de medidas de concordância, indicada pelos elementos da diagonal principal presentes na matriz de confusão, subtraídos da discordância encontrada pelos produtos das somatórias marginais das linhas e colunas da matriz de confusão (VIEIRA, 2000; CONGALTON; GREEN, 2019).

A introdução da estatística Kappa elaborada e proposta por Cohen (1960), possibilitou diversos estudos e pesquisas onde a concordância presente entre os avaliadores é corrigida pelo acaso. Cohen, originalmente elaborou o coeficiente Kappa para utilizações onde dois observadores distintos designam cada indivíduo a uma categoria de uma escala nominal, dessa forma, as abordagens de

discordâncias observadas e analisadas entre as avaliações distintas possuem pesos igualmente distribuídos (PINHEIRO, 2013).

Esse índice se baseia então na quantidade de respostas que são concordantes na análise, mais precisamente, a proporção de casos cujo os resultados encontrados são os mesmos entre os diferentes observadores. Dessa maneira, o índice Kappa proposto por Cohen (1960), pode ser calculado conforme a Equação 4.

$$K = \frac{N \sum_{i=1}^r X_{ij} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \quad (4)$$

Onde: K é o coeficiente Kappa; N é o número de observações; r é o número de linhas da matriz de erros; X_{ij} é a observação na linha i e coluna j; x_{i+} é o total marginal da linha i; e x_{+i} é o total marginal da coluna i.

Dessa maneira, o índice Kappa é considerado como sendo uma proporção de concordância interobservador, o qual permite avaliar tanto se a concordância está além do esperado tão somente pelo acaso, quanto o grau que é obtido pela mesma (SILVA; PAES, 2012; MASTELLA; VIEIRA, 2018).

Essa medida tem como proporção máxima de obtenção o valor unitário (1,00), que representa total concordância (100 %). Já os valores próximos e até mesmo abaixo de zero demonstram nenhuma concordância, ou a presença de uma eventual discordância encontrada entre os observadores, ou seja, um valor de índice Kappa menor do que zero, significa então que a concordância encontrada foi menor do que o esperado, se for obtida pelo acaso (discordância entre os diferentes observadores), mas esse valor negativo não possui uma interpretação estatística em termos de intensidade de discordância demonstrada pelo índice calculado (SILVA; PAES, 2012).

A avaliação da acurácia por meio do coeficiente de Kappa é utilizada para comparar a classificação obtida por dois ou mais observadores e somente quando a resposta à referida classificação estiver em uma escala categórica. O índice Kappa permite então ao observador ponderar e analisar se a medida que foi obtida é ou não satisfatória, para tanto, baseando-se e tendo o respaldo em dados consagrados de literatura e de outras pesquisas (SILVA; PAES, 2012; PINHEIRO, 2013). Landis e

Koch (1977), por exemplo, sugerem a interpretação e a qualidade de classificação apresentadas na Tabela 2 para os valores encontrados no cálculo do coeficiente Kappa.

Tabela 2 - Índice Kappa e a sua interpretação e qualidade de classificação.

Valores Kappa	Interpretação	Qualidade da classificação
< 0,00	Ausência de concordância	Péssima
0,00 a 0,20	Concordância pobre	Ruim
0,20 a 0,40	Concordância leve	Razoável
0,40 a 0,60	Concordância moderada	Boa
0,60 a 0,80	Concordância substantiva	Muito boa
0,80 a 1,00	Concordância quase perfeita	Excelente

Fonte: Landis e Koch (1977).

Contudo, o índice Kappa de maneira única não possui a competência para mostrar a existência de uma possível concordância encontrada entre dois mapas. Nesse caso, acaba sendo necessário avaliar também a significância estatística do valor obtido pelo índice Kappa, por meio de algum teste estatístico de significância (BATISTA, 2012).

Com base no valor do índice Kappa, podem então ser obtidos intervalos de confiança utilizando-se da variância amostral e a evidência de que a distribuição estatística do Kappa é normalmente assintótica (FIGUEIREDO; VIEIRA, 2007). Neste caso, a hipótese testada pode ser então avaliada pelo teste estatístico Z, que analisa o quanto uma medida se afasta da média, em termos relativos ao desvio padrão, analisando uma ou duas matrizes de erros normalmente distribuídas, identificando individualmente, um índice Kappa ou para duas classificações, onde para um teste individual, Z pode ser testado, assumindo uma hipótese nula ($Z = 0$), que acaba por ser rejeitada se Z for diferente de zero ($Z \neq 0$), ou se Z for maior que zero ($Z > 0$), o que indicará uma concordância maior do que o acaso (CONGALTON; GREEN, 2019).

O teste estatístico Z ainda pode utilizar-se da matriz de significância, que acaba por servir como sendo uma abordagem alternativa para comparação de

matrizes de erros independentes, com os resultados obtidos, analisados e sumarizados no formato de uma matriz (MASTELLA; VIEIRA, 2018). A estatística presente no teste Z, pode ser calculada conforme Congalton e Green (2019), conforme a equação 5.

$$Z = \frac{K}{\sqrt{\text{var}(K)}} \quad (5)$$

Onde: Z é unificado e normalmente distribuído; K é o valor do coeficiente Kappa; e $\sqrt{\text{var}(K)}$ é a variância da amostra do coeficiente Kappa.

A obtenção da variância de Kappa, pode ser fundamentada no método delta, proposto por Agresti (2002) e calculada conforme a Equação 6.

$$\text{var}(K) = \frac{1}{n} \left[\frac{\theta_1 (1 - \theta_1)}{(1 - \theta_2)^2} + \frac{2 (1 - \theta_1) (2 \theta_1 \theta_2 - \theta_3)}{(1 - \theta_2)^3} + \frac{(1 - \theta_1)^2 (\theta_4 - 4 \theta_2^2)}{(1 - \theta_2)^4} \right] \quad (6)$$

Onde: $\theta_1 = \frac{1}{n} \sum_{i=1}^c x_{ii}$; $\theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i+} x_{+i}$; $\theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_{ii} (x_{i+} x_{+i})$; e $\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_{ij} (x_{j+} + x_{+j})^2$.


3 MATERIAL E MÉTODOS

3.1 Materiais

3.1.1 Caracterização da área de estudo

A área de estudo situa-se na Fazenda Experimental Lageado, pertencente a Faculdade de Ciências Agrônômicas (FCA) e a Faculdade de Medicina Veterinária e Zootecnia (FMVZ) da UNESP, próxima ao Departamento de Engenharia Rural da FCA, em um trecho de APP do rio Lavapés, essa região está situada na divisa entre o perímetro urbano e rural do município de Botucatu (Figura 8), o qual está inserido na região Centro-Oeste do estado de São Paulo.

Figura 8 - Localização da área de estudo na Fazenda Experimental Lageado.




A área de estudo possui situação definida nas coordenadas UTM 763700 a 764300 Leste e 7470100 a 7471000 Sul, Fuso 22 S, Zona K (coordenadas

geográficas expressas em 48° 25' 52" a 48° 25' 24" de longitude W Gr. e 22° 51' 22" a 22° 50' 49" de latitude S) e apresentando uma área total de 30,35 ha.

O rio Lavapés está inserido na bacia hidrográfica do rio Tietê, na Unidade de Gerenciamento de Recursos Hídricos Sorocaba e Médio Tietê (UGRHI-10) do Sistema Estadual de Gerenciamento de Recursos Hídricos de São Paulo (SIGRH-SP).

Na região em que a Fazenda Experimental Lageado está situada, há a presença principalmente de terrenos de Formação Serra Geral, onde as formações basálticas, que devido a ação de agentes intempéricos, vão originar diferentes tipos de solos, devido ao fato desses materiais se encontrarem misturados com sedimentos neoceno-zóicos (CARVALHO; ESPÍNDOLA; PACCOLA, 1983). Com relação a litologia da área de estudo, além da Formação Serra Geral também ocorre a presença de Depósitos Terciários em menor proporção ao sul. Na Figura 9, tem-se a litologia da área de estudo, com base no levantamento geológico do Estado de São Paulo (LANDIM, 1984).

Figura 9 - Litologia da área de estudo.




O clima da região, conforme a classificação climática de Köppen, para o município de Botucatu é do tipo Cwa, sendo definido como subtropical úmido com inverno seco e frio e chuvas no verão com uma maior intensidade, a temperatura média anual é de 21,5 °C, com uma precipitação média anual de 1385,5 mm, conforme dados da Estação Meteorológica Lageado, pertencente a Faculdade de Ciências Agronômicas (FCA/UNESP) de Botucatu-SP.

Com relação a geomorfologia, a Fazenda Experimental Lageado e, conseqüentemente, a área de estudo, localiza-se sobre o Planalto Residual de Botucatu (Planalto Ocidental Paulista), em relação à cuesta basáltica, principalmente em locais que ocorrem sedimentos neoceno-zóicos (materiais mais grosseiros), onde também existe área de baixada a 150 m a noroeste (CARVALHO; ESPÍNDOLA; PACCOLA, 1983). Portanto, o relevo dessa região é classificado como de colinas com topos amplos, sendo que neste tipo de sistema de relevo predominam interflúvios com áreas superiores a 4 km², com topos extensos e aplainados, e vertentes com perfis retilíneos a convexos (IPT, 1981).

De acordo com Carvalho, Espíndola e Paccola (1983), existem oito classes pedológicas na Fazenda Experimental Lageado, sendo seis delas presentes na área de estudo. As mesmas foram atualizadas conforme a classificação pedológica proposta pela Embrapa (2018), dessa forma, as classes pedológicas encontradas na área de estudo são: LATOSSOLO VERMELHO Distrófico (LVd), solo de textura média e baixa saturação de bases nos primeiros 100 cm do horizonte B; LATOSSOLO VERMELHO Distroférrico (LVdf), solo de textura argilosa, baixa saturação de bases e alto teor de Ferro na parte dos primeiros 100 cm do horizonte B; NITOSSOLO VERMELHO Distrófico (NVd₁), solo com textura argilosa ou muito argilosa e baixa saturação de bases nos primeiros 100 cm do horizonte B; NITOSSOLO VERMELHO Distrófico transição para LATOSSOLO VERMELHO Distrófico (NVd₂), solo de textura média/argilosa; NEOSSOLO LITÓLICO Distrófico substrato basalto (RLd), Solos com horizonte A diretamente sobre a rocha matriz ou sobre horizonte C ou Cr; NEOSSOLO FLÚVICO Distrófico (RYbd), solo mal drenado, derivado de sedimentos aluviais com horizonte A ausente sobre horizonte C e que apresentam caráter flúvico dentro de 150 cm de profundidade. Na Figura 10, tem-se a pedologia da área de estudo, com base no levantamento de solos da Fazenda Experimental Lageado (CARVALHO; ESPÍNDOLA; PACCOLA, 1983).

Figura 10 - Pedologia da área de estudo.



A vegetação nativa remanescente da Fazenda Experimental Lageado é referente ao bioma de Mata Atlântica. Pela área de estudo estar situada em região de APP em um trecho do rio Lavapés, a formação nativa presente é a de floresta estacional semidecidual, que na área é oriunda da vegetação ciliar e que também se distribui paralelamente ao longo do rio, com uma composição florística rica e diversificada, reunindo espécies de famílias botânicas como *Fabaceae*, *Bignoniaceae* e *Arecaceae* (ANTONELLI; BATISTA, 2019).

A agricultura sempre fez parte da história da Fazenda Experimental Lageado e acompanhou fortemente a expansão da cafeicultura brasileira no início do século XX, com apogeu nos anos 20 até a crise da bolsa de valores de Nova York em 1929, sendo em seguida transformada em estação experimental de café e por fim em um espaço destinado ao ensino superior (ANTONINI, 1998). Na área de estudo, se tem como atividades agrícolas a parte do Sítio Modelo, bem como área de pesquisa de campo do Departamento de Engenharia Rural da FCA e área de pastagem da FMVZ.

3.1.2 Drone e plataforma de operação

As imagens aéreas foram obtidas por meio de um drone do tipo multirrotor (quadrirotor), da marca/modelo 3DR Solo (Figura 11).

Figura 11 - Drone quadrirotor 3DR Solo.



O drone possui comandos de voo em três eixos, sendo: *pitch*, o comando responsável por movimentar o veículo para frente e para trás; *roll*, para o movimento de direita para esquerda; *elevator*, para os movimentos de subir e descer; e *yaw*, responsável pelo movimento de rotação no próprio eixo. O sistema denominado *Inertial Measurement Unit* (IMU), possibilita controlar a altitude de voo por meio de um sensor de inércia e altímetro barométrico. Outro sistema importante para o drone é o *Compass*, que é responsável por auxiliar o GPS, realizando a leitura da informação geomagnética, dessa forma, proporcionando melhor acurácia da posição e da altura do veículo. O drone possui também o *Gimbal*, que consiste em um sistema de estabilização da câmera, proporcionando melhor qualidade dos produtos (imagens e vídeos) coletados pela plataforma quando em voo.

3.1.3 Equipamentos e softwares utilizados

Utilizou-se de um equipamento *Global Navigation Satellite System* (GNSS) *Real Time Kinematic* (RTK) de alta performance da marca TechGeo, modelo GTRi, com precisão centimétrica para a coleta de um total de 35 pontos de controle a nível de campo para o georreferenciamento dos mosaicos de imagens.

Foram utilizados os sensores MAPIR Survey3W RGB (0,380 a 0,740 μm) e MAPIR Survey3W NIR/InfraRED (0,725 a 1,10 μm), ambos com resolução de 12.1 *Megapixels* (Figura 12).

Figura 12 - Sensores MAPIR: Survey3W RGB e Survey3W NIR/InfraRED.



No total foram coletadas quinhentos e oitenta e nove (589) imagens para a construção de cada ortomosaico. As imagens foram obtidas no dia 17 de julho de 2018, que corresponde ao período de inverno e de seca para região de Botucatu-SP.

O alvo de calibração terrestre (*calibration ground target*) da MAPIR, foi utilizado para a calibração e correções de reflectância dos sensores da mesma (MAPIR Survey3W RGB e MAPIR Survey3W NIR/InfraRED).

Também foi utilizado o *tablet* da marca AOC e modelo *TABLET breeze™ 8"* para o auxílio no controle do drone bem como para a instalação do *software* de telemetria para a execução da missão de voo.

O *software* livre do tipo *ground station Mission Planner 1.3.7* foi utilizado para a programação da missão, definição do trajeto e da linha de voo, telemetria entre o drone e a plataforma móvel e demais informações referentes a missão.

O aplicativo de fotogrametria e fotointerpretação Pix4Dmapper 3.0 foi utilizado para a geração dos ortomosaicos RGB e infravermelho e o georreferenciamento dos mesmos, separação da corrente do vermelho da imagem RGB e o cálculo e geração do índice radiométrico do NDVI.

Utilizou-se do *software* SIG livre e aberto SPRING 5.5.6 para o processo de divisão e segmentação dos ortomosaicos (RGB e NDVI), possibilitando a implementação da análise de imagens baseada em objetos (OBIA).

O *software* ArcGIS 10.5 foi utilizado para a validação da acurácia das classificações geradas, gerando a matriz de confusão utilizada para o cálculo do índice Kappa, além de ser usado para toda a vetorização e criação de *buffers* e também para a finalização e geração do *layout* de todos os mapas gerados.


Por fim, utilizou-se de dois programas da Microsoft do Pacote Office 2019, o Word e o Excel. O Word, consiste em um *software* processador de texto que permite criar e compartilhar documentos, sendo utilizado para a edição e revisão de textos. Já o Excel, consiste em um *software* editor de planilhas que permite a construção de tabelas, fórmulas e gráficos, sendo este utilizado para os cálculos de área e porcentagens das classificações, para os cálculos estatísticos de Kappa e teste Z, e a criação dos gráficos.

3.1.4 Dados meteorológicos

As imagens da área de estudo para a obtenção do NDVI foram coletadas no período de seca/inverno. A escolha por essa época do ano se deve ao fato de ser a melhor para observar a diferença entre as espécies de porte arbóreo e herbáceo, sendo mais fácil de distingui-las como observado por Sartori et al. (2009), Demarchi, Piroli e Zimback (2011), França et al. (2013), Albuquerque et al. (2014), Machado et al. (2014) e Tagliarini et al. (2017), já que as plantas herbáceas são mais sensíveis aos períodos de estiagem (seca), dessa maneira os valores mais altos do índice de vegetação serão das plantas de porte arbóreo presentes na APP.

Na Figura 13 é possível observar a média histórica de precipitação do município bem como a média de precipitação do ano de 2018, com os dados de pluviosidade obtidos da Estação Meteorológica Lageado.

Figura 13 - Comportamento da pluviosidade no ano de 2018 em Botucatu-SP.



Para saber o melhor período de obtenção das imagens foi realizada uma análise com base no perfil histórico de precipitação anual no município de Botucatu-SP. A região de Botucatu-SP, apresenta um perfil regular de chuvas anuais, com destaque para os meses de dezembro, janeiro e fevereiro como os mais chuvosos e o período de estiagem ocorrendo a partir do mês de abril até o final de agosto. Ainda


na Figura 13 é possível notar os meses mais chuvosos e secos de Botucatu-SP e observa-se que o mês de julho de 2018, mês de obtenção das imagens aéreas da área de estudo, foi o mais seco do ano, com menor regime de precipitação, em concordância com a média histórica de pluviosidade do município utilizada como base para se chegar no período em questão.

3.2 Métodos

3.2.1 Procedimentos adotados

Na Figura 14, apresenta-se de forma sucinta, um fluxograma de trabalho e as principais etapas de como foram realizados os procedimentos de atividades adotados nesta pesquisa.


Figura 14 - Fluxograma de trabalho.



3.2.2 Programação de voo

A definição da linha do voo e, conseqüentemente, da área imageada foi estabelecida a nível de campo e, posteriormente, com o auxílio do *software* de planejamento de missões *Mission Planner* 1.3.7, o que possibilitou a programação e definição da altura desejada, ângulo de inclinação e velocidade de voo, bem como as áreas e a porcentagem de sobreposição frontal e lateral das imagens, além de especificações da câmera embarcada (Figura 15).

Figura 15 - Programação da linha de voo no *software* *Mission Planner*.



A velocidade de voo estipulada foi de 7 m/s (25,2 km/h). As imagens possuem recobrimento/sobreposição tanto frontal (*overlap*) como lateral (*sidelap*) de 80,00 %. A altura do voo estipulada foi de 70 m, buscando-se uma melhor resolução das imagens, estando dentro do regimento da ANAC e seguindo as regras gerais para o uso civil de aeronaves não tripuladas em território brasileiro (ANAC, 2017). Para o cálculo da área de recobrimento das imagens obtidas pelo drone, foi utilizada a equação (Equação 7) proposta por Falkner e Morgan (2001).

$$Ac = \left(\frac{Av}{Df \times Ls} \right) \times \left(\frac{Av}{Df \times Cs} \right) \quad (7)$$


Onde: Ac é a área coberta (m^2); Av é a altura de voo (m); Df é a distância focal (mm); Ls é a largura do sensor (cm); e Cs é o comprimento do sensor (cm).

Outro importante fator estabelecido para a aerofotogrametria por imagens de drone foi o *Ground Sample Distance* (GSD), que em tradução livre significa distância de amostra do solo. O GSD consiste na distância entre os pontos centrais de cada

amostra obtida em relação ao solo (PROPELLER AERO, 2018), que no caso de aerofotos digitais, cada amostra corresponde a um *pixel*. De forma simplificada, o GSD pode ser definido como o quão grande é o tamanho de cada *pixel* na imagem.

Em vias gerais, o GSD (Figura 16) corresponde a resolução espacial das imagens obtidas por drone, onde um GSD de 3,0 cm corresponde a um *pixel* na imagem de 3,0 cm, que por sua vez corresponde a mesma medida no real (nível de campo). Estando intimamente relacionado com a altura de voo, dessa forma, quanto menor for a altura de voo do drone, menor será o seu valor de GSD, e maior será a sua resolução espacial, resultando em uma imagem com alto grau de detalhamento.

Figura 16 - Ground Sample Distance (GSD) de imagens de drone.



Fonte: Adaptado de Propeller Aero, 2018.

O GSD pode ser calculado (Equação 8) com base em um conjunto de três fatores que são: a altura de voo, a distância focal do sensor e o tamanho do *pixel* obtido pelo sensor, conforme Miřijovský e Langhammer (2015).

$$GSD = \left(\frac{\rho' \times Hg}{f} \right) \quad (8)$$


Onde: GSD é o *Ground Sample Distance* (cm); ρ' é o tamanho do *pixel* (mm); Hg é a altura de voo (m); e f é a distância focal (mm).

Em todas as imagens obtidas referentes a área de estudo, foi utilizado GSD de 3,5 cm, em razão da altura de voo empregada, objetivando maior resolução das imagens e seguindo as normas e diretrizes da ANAC.

3.2.3 Georreferenciamento e ortomosaicos retificados

Com a utilização do receptor GNSS RTK foi possível a obtenção de pontos de controle (Figura 17), para amarrar o processo de retificação das imagens, calibrando os mosaicos e georreferenciando, melhorando a acurácia do posicionamento.

Figura 17 - Pontos de controle GNSS dos ortomosaicos.



Os levantamentos produziram algumas centenas de imagens aéreas em formato digital de arquivo .JPEG, além de arquivos adicionais para sincronizar o

conjunto de cenas obtidas, possibilitando a alocação de pontos de amarração entre cada imagem, utilizando-se de coordenada geográfica plana UTM, com o datum SIRGAS 2000, sistema de referência geocêntrico oficial do Brasil.

Foram gerados dois mosaicos com as imagens de alta resolução obtidas pelo drone, um com imagens na faixa do espectro visível (RGB) e outro na região do infravermelho próximo (NIR). As imagens de ambos os mosaicos, foram obtidas de forma simultânea com os dois sensores específicos acoplados ao drone (Figura 18).

Figura 18 - Sensores acoplados ao drone 3DR Solo.



As imagens do mosaico no espectro visível (0,380 a 0,740 μm) foram obtidas por meio do sensor MAPIR Survey3W RGB, enquanto que as imagens do mosaico no espectro do infravermelho próximo (0,725 a 1,10 μm) foram coletadas pelo sensor MAPIR Survey3W NIR/InfraRED, podendo ambos gerarem imagens multiespectrais com GSD de até 3,5 cm.

As imagens digitais coletadas foram processadas no *software* de aerofotogrametria Pix4Dmapper 3.0, com processamento em nuvem, onde foram construídos os dois mosaicos ortorretificados (RGB e NIR) e que posteriormente

foram georreferenciados com base nos pontos de controle obtidos por GNSS RTK. No Pix4Dmapper também foi realizada a identificação e extração das correntes predominantes por meio do cálculo matricial entre as bandas dos espectros vermelho (extraído do sensor MAPIR Survey3W RGB) e do infravermelho próximo (extraído do sensor MAPIR Survey3W NIR/InfraRED), necessárias para a obtenção do índice radiométrico NDVI.

Para uma análise mais detalhada e refinada da APP nas margens do rio Lavapés, ao longo da área de estudo, foi delimitado adequadamente com base no Código Florestal, Lei nº 12.651, com as modificações da Lei nº 12.727, ambas de 2012, um perímetro (*buffer*) de 30 m e com 5,96 ha de área, referente às APP hídricas da localidade, utilizando-se do *software* ArcGIS 10.5, por meio do comando *Geoprocessing* e da ferramenta *Buffer*.

3.2.4 Índice de Vegetação por Diferença Normalizada (NDVI)

Com as imagens do melhor período para análise e a posterior obtenção das correntes predominantes dos espectros do vermelho (obtido da imagem RGB) e do infravermelho próximo (obtido da imagem NIR/InfraRED) das mesmas, essas imagens coletadas foram agrupadas formando um ortomosaico. Para a obtenção do índice radiométrico NDVI foi utilizada a função *Raster Calculator* do *software* Pix4Dmapper 3.0. Dessa forma, o índice de vegetação foi obtido por meio da razão entre a diferença e a soma das refletividades dos espectros do infravermelho próximo e do vermelho visível.

Os índices de vegetação são medidas radiométricas adimensionais, dessa maneira, os valores de NDVI são encontrados no intervalo de valores que vai do -1 a 1, onde os valores de 0 a 1 indicam vegetação com baixa até alta atividade fotossintética, já os valores menores que 0 até -1, são indícios de áreas com presença de rochas ou solo exposto, áreas impermeabilizadas e corpos d'água superficiais.

A clorofila presente na folha dos vegetais, absorve a radiação solar no espectro vermelho, ocasionando em baixa reflectância. Enquanto que com relação

ao espectro do infravermelho próximo, a reflectância da radiação solar incidente é alta, devido a morfologia das folhas e da estrutura da vegetação, dessa maneira, quando maior for o contraste, maior será o vigor da vegetação imageada (LOURENÇO; LANDIM, 2004).

Dessa forma, o índice radiométrico NDVI foi obtido conforme cálculo (Equação 9) baseado em Rouse, Haas e Schell (1974) e Tucker (1979), sendo este um indicador sensível à vegetação, e calculado por meio das variáveis de refletância do infravermelho próximo e do vermelho visível.

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

Onde: NDVI é o Índice de Vegetação por Diferença Normalizada (adimensional); ρ_{NIR} corresponde a refletância do infravermelho próximo (0,725 a 1,100 μm); e ρ_{RED} corresponde a refletância na faixa do espectro vermelho visível (0,630 a 0,700 μm).

3.2.5 Calibração da reflectância dos mosaicos RGB e NIR/InfraRED

Ao se trabalhar com índices radiométricos como o NDVI, é importante se atentar aos efeitos que podem afetar a natureza das imagens obtidas via sensoriamento remoto de várias maneiras. Dessa forma, a correção da reflectância e de variáveis atmosféricas (correção atmosférica) são consideradas como passos essenciais para o processamento digital de imagens, melhorando a qualidade das informações contidas nas mesmas e garantindo confiabilidade nos resultados obtidos.

As imagens de drone, por serem produtos multiespectrais de baixa altitude e serem obtidas por plataformas sub-orbitais, não precisam de correções de influências atmosféricas de maior altitude por fenômenos de espalhamento, absorção e refração da energia eletromagnética, como nas imagens de plataformas orbitais (satélites). Diferente das imagens de satélites, as imagens de drone necessitam apenas de correções de reflectância dos seus próprios sensores,

corrigidas durante o próprio voo do drone com a utilização de um *calibration ground target* (Figura 19).

Figura 19 - Calibration ground target da MAPIR para calibração de reflectância.



O *calibration ground target* consiste em um alvo terrestre alocado ao nível do solo, que possui curvas de reflectância conhecidas, podendo ser capturado a partir de qualquer ângulo durante a execução do voo, graças as suas propriedades difusas de reflexão. Essa correção de reflectância que o *calibration ground target* proporciona uma melhora referente a normalização das imagens aéreas obtidas e, dessa maneira, melhora consequentemente a geração dos produtos finais do levantamento, ou seja, dos mosaicos em RGB e infravermelho e do índice de vegetação (NDVI).

Dessa forma, foi realizado previamente um voo teste com o drone para a obtenção de imagens com a finalidade de correção da reflectância dos sensores embarcados, utilizando-se do alvo terrestre de calibração da MAPIR, para em seguida iniciar o levantamento para a obtenção das imagens aéreas da área utilizadas no presente estudo.

3.2.6 Processo de segmentação e classificação OBIA

Para a avaliação da área de estudo foram utilizadas imagens com elevada resolução espacial coletadas por drone, porém sobrepondo a adversidade causada pelo parâmetro escala (não englobou objetos reais), desse modo, minimizando possíveis erros adicionais de áreas menores que os objetos, o que em tese se tornou viável na definição da escala proposta no estudo, seguindo as metodologias de Gabriel (2013) e Neves (2013).

Cada segmento de imagem possui informações de cor e forma, sendo cada elemento descrito por um conjunto de variáveis associadas ao mesmo. De forma contrária ao modo tradicional de análise baseada em *pixels*, foi realizada a análise de imagem baseada em objeto (*Object Based Image Analysis*), em que a referência de amostra são os objetos elaborados por meio de algoritmos de segmentação e não os *pixels* em si, conforme demonstrado por Benz et al. (2004), Vieira (2010) e Saraiva (2013).

O parâmetro escala, que consiste no critério de semelhança foi utilizado para definir a uniformidade dos segmentos. Além da escala, outros dois parâmetros foram utilizados para descrever a separação entre objetos diferentes na imagem, que são: a tonalidade (coloração espectral) e a compacidade (suavização e forma). Sendo que estes parâmetros controlam a heterogeneidade presente entre segmentos e objetos em análise (BAATZ; SCHÄPE, 2001).

As características dos objetos, como escala, coloração e forma, bem como a janela de varredura da imagem, permitiram a classificação das APP hídricas no trecho em estudo por meio de funções empregando a classificação OBIA, junto ao *software* SIG SPRING 5.5.6, que permitiu o processo de segmentação das imagens e, posteriormente, a classificação dos usos e ocupação do solo encontrados na área de estudo.

O algoritmo de segmentação do SPRING divide a imagem em *pixels*, segmentando a imagem de maneira uniforme, sem realçar algum possível segmento ou objeto de interesse, possibilitando assim uma análise equiparada e linear entre os diferentes ensaios de segmentação realizados.

Esse algoritmo também possibilitou a identificação de objetos na imagem em diferentes escalas, ou seja, os mesmos são divididos em diferentes classes, conforme o nível hierárquico da classificação. O desenvolvimento da segmentação ocorreu por meio do processo heurístico de decisão, baseando-se na heterogeneidade das características espectrais e espaciais dos objetos que estão sendo analisados durante o processo de segmentação da imagem.

Os principais parâmetros a serem manipulados na fase de segmentação das imagens são: a escala, que está intimamente relacionada com o nível de similaridade entre os objetos; a área (*pixels*), que corresponde à abertura da janela de varredura das imagens; e a relevância a dar às variáveis cor (tonalidade) e compacidade (forma), relacionadas com a heterogeneidade entre os objetos, onde se optou por atribuir valores proporcionais entre os dois fatores, devido as características do algoritmo de segmentação.

O processo de segmentação se inicia com um objeto ou região inicial de análise, que acaba sendo comparado com outros objetos ao seu redor, calculando-se assim a heterogeneidade existente entre cada um dos objetos antes e após o processo de fusão. As diferenças encontradas para os dois momentos, acaba por definir o custo de fusão dos objetos gerados no processo, ou seja, buscando-se a menor heterogeneidade possível entre os objetos em análise.

O grau de heterogeneidade encontrado em um objeto pode ser definido basicamente por dois componentes que são: a heterogeneidade espectral e a heterogeneidade espacial, que levam em consideração a coloração (cor) e a compacidade (forma) dos segmentos (objetos), como demonstrado por Luz, Antunes e Tavares Júnior (2010) e Aragão et al. (2015).

Dessa forma, foi possível a elaboração de diferentes ensaios de segmentação para a manipulação dos parâmetros de maior relevância para a geração de objetos, a fim de se obter um melhor grau de segmentação e, conseqüentemente, uma melhor classificação dos objetos gerados pelo algoritmo de segmentação (Crescimento de Regiões Baatz) do *software* SPRING 5.5.6. Na Tabela 3, tem-se o registro dos ensaios que obtiveram as melhores escalas de segmentação no processo de análise.

Tabela 3 - Parâmetros manipulados no processo de segmentação.

Similaridade	Área (<i>pixels</i>)	Cor	Compacidade	Nº de objetos
	16			122
50	9	0.50	0.50	163
	4			145
	16			859
30	9	0.50	0.50	904
	4			897
	16	0.50	0.50	8255
10	9	0.75	0.25	10361
	4	0.25	0.75	7844

Com base nos ensaios obtidos, foi possível analisar qual deles resultou na formação de um maior número de objetos no processo que, conseqüentemente, proporciona um maior detalhe no processo de classificação do uso e ocupação do solo posteriormente, conforme descrito por Gabriel (2013) e Neves (2013). Assim, o ensaio com valor de similaridade (escala) de dez (10), valor de nove (9) para área (*pixels*), valor de 0.75 para cor (tonalidade), valor de 0.25 para compacidade (forma) e gerando no total 10361 objetos, foi o escolhido como a escala de segmentação para o estudo.

Após a segmentação das imagens, iniciou-se o processo de classificação por níveis da OBIA, pelo classificador *Bhattacharya*. Este classificador consiste em um algoritmo do *software* SPRING, que necessita da seleção de áreas de treinamento, podendo essas serem obtidas no próprio processo de segmentação, ou por polígonos que representam amostras das classes identificadas.

A partir das amostras de treinamento, tem-se estimada a função correspondente a densidade de probabilidade das classes especificadas, e então é calculada a distância *Bhattacharya* entre as classes e as regiões segmentadas. A medida da distância de *Bhattacharya* é usada para medir a separabilidade estatística entre um par de classes espectrais, medindo a distância média entre as distribuições de probabilidades das classes espectrais (CAMPOS et al., 2013).

Dessa forma, foram identificadas quatro classes referentes ao uso e ocupação do solo em APP hídrica da área de estudo que são: leito do rio, sombras, vegetação arbórea e vegetação herbácea. Na Tabela 4, tem-se as quatro classes obtidas para a OBIA, bem como o número de áreas de treinamento usadas e suas áreas correspondentes.

Tabela 4 - Distribuição de áreas de treinamento e classes OBIA.

Classes	Nº de áreas de treinamento	Área amostrada (m²)
Leito do Rio	32	505,03
Sombras	21	279,48
Vegetação Arbórea	45	2158,22
Vegetação Herbácea	39	489,37

3.2.7 Validação estatística das classificações

Para o processo de avaliação da segmentação e da classificação OBIA obtida, foi realizado um cruzamento entre verdade terrestre (VT) da área de estudo, com as classificações obtidas dos ortomosaicos em RGB e NDVI, com a finalidade de se obter a acurácia dessas classificações. Também foi realizada a comparação entre as duas classificações (OBIA RGB e OBIA NDVI) para medir a correlação entre ambas.

Dessa maneira, tendo a VT da área de estudo, como sendo o referencial e real utilização do solo, desmontando assim, a acurácia das classificações OBIA, cruzando as matrizes de segmentos. Assim, foram calculados a exatidão global, conforme Bishop, Fienberg e Holland (1975) e o coeficiente de Kappa conforme Cohen (1960).

Tanto a exatidão global quanto o índice Kappa, são calculados por meio da utilização de uma matriz de confusão. A matriz por sua vez, é gerada após a verificação dos resultados obtidos na classificação digital da imagem de alta resolução, cruzada com a VT.

Para se chegar na matriz de confusão, foram construídos 30 polígonos de amostra no *software* SIG ArcGIS 10.5, para cada uma das classes de uso e ocupação do solo identificadas nas classificações OBIA RGB e OBIA NDVI, distribuídos de forma aleatória sobre o *buffer* da APP. Após a construção dos polígonos é necessária a conversão desses arquivos vetoriais para arquivos matriciais (*rasters*) para a comparação com o mapa da VT da área, utilizando-se da ferramenta de conversão do ArcGIS.

Em seguida, utilizou-se da ferramenta *Combine* do *Spacial Analyst Tools* para a exata combinação das classes das amostras, com a mesma localização encontrada na VT. Após essa etapa, cria-se um arquivo *dBASE Table*, que foi utilizado para a criação de uma tabela dinâmica (*pivot table*) pela ferramenta *Table* do *Data Management Tool* do ArcGIS.

Com a tabela dinâmica referente a matriz de confusão criada, exporta-se ela em arquivo de texto (.txt), possibilitando sua leitura pelo *software* Excel do Pacote Office 2019. No Excel é possível organizar a matriz de confusão na forma de tabela, criar gráficos e calcular a acurácia de cada mapeamento por meio da exatidão global e, principalmente do índice Kappa, enquadrando os resultados obtidos de Kappa, conforme Landis e Koch (1977), em uma escala de qualidade e interpretação dos valores obtidos referente a cada classificação.

Utilizando-se de dados derivados dos cruzamentos das próprias classes, onde os mesmos situam-se na diagonal principal da matriz de confusão, dessa forma, garantindo ao índice Kappa maior precisão da acurácia em relação a outros métodos, devido à medição dos *pixels* estarem corretamente classificados, em relação à probabilidade dos mesmos estarem incorretamente classificados, avaliando assim a acurácia temática por ser mais respondível às variações causadas por erros de omissão e comissão (DEMARCHI; PIROLI; ZIMBACK, 2011; AL-SHARIF; PRADHAN, 2014; RODRIGUES et al., 2016).

Dessa forma, tendo a matriz de confusão como base fica possível calcular os erros de omissão de cada classe, bem como os riscos e confiança do usuário, e também os erros de comissão e os riscos e confiança do produtor para cada uma das classes de uso e ocupação do solo.


Por fim, para testar a significação de cada matriz de confusão e a validação estatística do índice Kappa, foi calculado também o teste estatístico Z, conforme Congalton e Green (2019) e a variância de Kappa pelo método delta, proposto por Agresti (2002). Onde Se $Z \geq Z_{\alpha/2}$ a classificação é significativamente melhor que uma distribuição aleatória, onde $\alpha/2$ é o nível de confiança nos dois lados da curva no teste Z e o número de graus de liberdade é assumido ser infinito. Assim sendo, o teste de significância estatística empregado no estudo, seguiu a hipótese nula onde, com um intervalo de confiança de 5 %, $|Z| > 1,96$ para considerar as classificações como significativamente diferentes, conforme proposto por Congalton e Green (2019).

4 RESULTADOS E DISCUSSÃO

4.1 Ortomosaicos retificados

Com as missões de coleta de informações com o drone, foi possível a obtenção das imagens para a geração dos ortomosaicos retificado em RGB e infravermelho próximo (Figura 20).

Figura 20 - Ortomosaicos RGB (A) e infravermelho (B) da área de estudo.



LEGENDA

**Ortomosaicos
RGB (A) e InfraRED (B)**

SISTEMA DE COORDENADAS UTM
DATUM: SIRGAS 2000
FUSO: 22 S
GSD: 3,5 cm
ESCALA: 1:2.500
Elaboração: Felipe de Souza N. Tagliarini, 2020



Com a utilização de um GSD de 3,5 cm, as imagens coletadas possuem uma resolução espacial de mesmo valor e um alto grau de detalhamento dos objetos presentes na paisagem da área de estudo, sendo possível até mesmo observar as sombras de árvores na zona de APP.

A obtenção do conjunto de imagens no dia 17 de julho de 2018, ou seja, no período de inverno (estiagem) na região do município de Botucatu-SP, colaborou para uma distinção nítida entre os indivíduos de porte arbóreo da vegetação ciliar do rio Lavapés, para a vegetação herbácea ao redor, conforme constatado também por Albuquerque et al. (2014), Machado et al. (2014) e Tagliarini et al. (2017).


Na imagem do ortomosaico retificado na região do infravermelho e infravermelho próximo (NIR/InfraRED), fica nítida a distinção encontrada entre as formas de vegetação e os outros elementos da paisagem (alvos abióticos), como edificações, solo exposto e água, que ficam mais evidentes ainda nessa região do espectro, devido as plantas refletirem principalmente o comprimento de onda do infravermelho próximo.

4.2 NDVI como instrumento no diagnóstico ambiental

Por meio do cálculo entre a razão da diferença das refletividades do vermelho visível, referente ao ortomosaico RGB e do infravermelho próximo, referente ao ortomosaico NIR/InfraRED, pela soma das refletividades das mesmas, foi possível então obter o NDVI da área de estudo, em uma região considerada como um trecho de divisa entre o perímetro urbano e rural do município de Botucatu-SP.

Os resultados obtidos do índice radiométrico NDVI (Figura 21), apresentaram valores que variaram na faixa de -1 a 1, onde os valores mais próximos a 1, apresentam predominantemente, vegetação arbórea com indício de alta atividade fotossintética da mesma, enquanto que os valores próximos a -1, indicam alvos abióticos das imagens, como demonstrado por áreas com solo exposto, áreas com ausência de culturas, edificações e corpo d'água (rio Lavapés).

Figura 21 - Ortomosaico NDVI da área de estudo.



De forma geral, o ortomosaico em NDVI apresentou extensas áreas, principalmente, nas proximidades da região de APP hídrica, com tonalidades de verde claro e verde escuro, que são indicativos de uma alta atividade fotossintética e consequente maior acúmulo de biomassa pela vegetação, que indicam espécies de porte arbustivo e arbóreo, predominantemente, presentes na área de estudo. Já a tonalidade em amarelo, indica a presença, principalmente, de vegetação de porte herbáceo com uma atividade fotossintética mais baixa, por serem mais sensíveis ao período de estiagem e de menor precipitação em que foram feitas as tomadas aéreas da área de estudo.

Enquanto que a coloração alaranjada representa áreas com ausência de vegetação e exposição do solo. E por fim, as regiões com tonalidade avermelhada, indicam localidades que são impermeabilizadas, como edificações e afloramentos rochosos, e também corpos d'água e locais com a presença de água superficial no solo. Na Tabela 5, é possível observar a distribuição em área e porcentagem dos valores referentes ao índice radiométrico do NDVI, encontrados para a área de estudo.

Tabela 5 - Valores de NDVI da área de estudo e sua representatividade.

Valor de NDVI	Tonalidade	Área (ha)	Área (%)
< 0,00	Vermelho	3,09	10,17
0,00 - 0,20	Laranja	10,44	34,31
0,20 - 0,40	Amarelo claro	6,30	20,77
0,40 - 0,60	Amarelo escuro	0,45	1,48
0,60 - 0,80	Verde claro	9,91	32,65
0,80 - 1,00	Verde escuro	0,16	0,53
TOTAL	-	30,35	100,00


Pela perspectiva de distribuição espacial da vegetação de porte arbóreo e arbustivo e levando-se em conta os maiores valores referentes ao NDVI, é possível observar as similaridades dos resultados obtidos entre o ortomosaico em NDVI com as observações feitas por Sartori et al. (2009), Demarchi, Piroli e Zimback (2011) Barbosa, Carvalho e Camacho (2017) e Tagliarini et al. (2017) que utilizaram do mesmo índice de vegetação, ao aplicarem respectivamente, no município de Botucatu-SP, no município de Santa Cruz do Rio Pardo-SP, na Região Serrana de Martins e Portalegre-RN e na bacia hidrográfica do córrego do Petiço no município de Botucatu-SP, obtendo valores na faixa de 0,40 a 0,50 e 0,45 a 0,70, respectivamente.

Matese et al. (2015), ao aplicar e comparar os valores de NDVI encontrados por meio da utilização de diferentes plataformas, como drone, aeronave tripulada e satélite, para obtenção de imagens com diferentes resoluções espaciais e, consequentemente, diferentes graus de detalhamento, segundo os autores, a utilização do drone como plataforma de imageamento, obteve os melhores resultados para áreas com gradientes de vegetação mais espesso e/ou com um alto grau de heterogeneidade, pois as imagens de menor resolução obtidas pelas outras plataformas, não proporcionam o mesmo grau de detalhamento em áreas com vegetação arbustiva e arbórea, dessa maneira, falham em representar parte da variabilidade fotossinteticamente ativa dessas formações vegetais.

4.3 Análise das APP da área de estudo

Para uma análise mais detalhada referente ao uso e ocupação do solo na APP hídrica da área de estudo, foi realizado um recorte (*buffer*) nos ortomosaicos em RGB e infravermelho de 30 m (Figura 22), com uma área total de 5,96 ha, seguindo a legislação florestal vigente, Lei nº 12.651, com as modificações propostas na Lei nº 12.727 de 2012.

Figura 22 - Buffer APP em RGB (A) e infravermelho (B) da área de estudo.




Dessa maneira, pode-se distinguir com maior facilidade os diferentes padrões e tipos de ocupação do solo, bem como da vegetação, devido as diferentes espécies nativas, exóticas e agrícolas presentes na região de APP da área de estudo.

O recorte do *buffer* da APP hídrica referente ao ortomosaico em infravermelho próximo, torna a distinção entre a vegetação ciliar do rio Lavapés e os demais usos do solo presentes na área de estudo ainda mais evidentes, devido ao comportamento espectral por parte da vegetação de porte arbóreo, arbustivo e herbáceo existentes na região, pois a vegetação reflete principalmente o espectro de radiação referente a faixa do infravermelho próximo. Sendo assim, fica possível identificar usos e ocupações do solo inadequados na região de APP, apenas observando o comportamento espectral da vegetação.

A sensibilidade de resposta obtida pelo NDVI (Figura 23) mostra que uma considerável proporção de APP, em uma análise espacial do *buffer* de 30 m, foi ocupada de maneira irregular, ou possui formas de vegetação consideradas como sendo não adequadas para a constituição da vegetação ciliar na área de estudo.

Figura 23 - Buffer APP em NDVI referente à área de estudo.



O leito do rio Lavapés, apresentou valores negativos de NDVI, bem próximos ao valor de -1, com uma tonalidade avermelhada e exibindo um comportamento espectral bem típico desse alvo abiótico terrestre, uma vez que ao contrário das formações vegetais (alvos bióticos), não reflete o comprimento de onda na faixa do infravermelho próximo e sim o absorve, semelhante aos resultados obtidos por Sartori et al. (2009), Demarchi, Piroli e Zimback (2011), Rodrigues e Rodrigues (2012), Barbosa, Carvalho e Camacho (2017) e Tagliarini et al. (2017), que demonstram que o índice radiométrico do NDVI apesar de ser idealizado para a detecção de forma de vegetação, devido aos comprimentos de onda empregados para o seu cálculo, também identifica de forma bem destacada os corpos d'água presentes nas imagens digitais.

Essa faixa de valor negativo do índice de vegetação, além da região do leito, pode corresponder a áreas como geoformas poligonais de alvos correspondente a presença de corpos d'água, solos descobertos, afloramentos rochosos, e edificações rurais. A distribuição espacial dos valores negativos (entre 0 e -1) ocorre de forma dispersa ou agrupada, localizadas ao longo de toda a faixa de APP hídrica. Na Tabela 6, é possível observar a distribuição em área e porcentagem dos valores referentes ao índice radiométrico do NDVI, encontrados para a zona de APP da área de estudo.

Tabela 6 - Valores de NDVI da APP e sua representatividade.

Valor de NDVI	Tonalidade	Área (ha)	Área (%)
< 0,00	Vermelho	0,89	14,93
0,00 - 0,20	Laranja	0,40	6,75
0,20 - 0,40	Amarelo claro	1,10	18,51
0,40 - 0,60	Amarelo escuro	1,34	22,48
0,60 - 0,80	Verde claro	2,18	36,64
0,80 - 1,00	Verde escuro	0,05	0,69
TOTAL	-	5,96	100,00

Já os valores positivos de reflectância oscilando entre 0,40 a 0,80, apontam taxa de atividade fotossintética mais elevada, com presença predominantemente de vegetação arbórea mais densa, indicando uma correta cobertura do solo referente a vegetação ciliar presente na zona de APP. Enquanto que os valores agrupados entre a faixa de valores de 0,00 a 0,40, indicam uma taxa de atividade fotossintética mais baixa, ocorrendo uma mistura espectral de áreas sem vegetação, ou com a presença de cobertura vegetal menos densa, como arbustos e principalmente a classe de vegetação herbácea, em concordância com os valores obtidos por Matese et al. (2015) obtidos por meio de drone para o levantamento em viticultura, em que os autores também encontraram alvos com mistura espectral com áreas sem vegetação, atrapalhando na correta identificação da classe presente com o valor de NDVI encontrado.

Na Figura 24, com uma das imagens referentes ao ortomosaico em RGB, pode-se observar como parte dos 30 m referentes à APP hídrica em que se deveria conter vegetação de porte arbóreo na faixa ciliar do rio Lavapés, foi substituída de forma incorreta por outras utilizações do solo como gramíneas (herbáceas), e fragmento de área agrícola, não indo de acordo com o que está presente na legislação florestal vigente.

Figura 24 - Uso incorreto do solo em APP do rio Lavapés.



Foto: Felipe de Souza Nogueira Tagliarini, 2020.

4.4 Análise da segmentação e classificação OBIA

A medida de similaridade (escala) utilizada para se construir o processo de segmentação de imagens, determina a qualidade da mesma sendo um dos principais fatores avaliados (ZHANG; FRITTS; GOLDMAN, 2008; BARBOSA et al., 2017). As imagens áreas obtidas por drone, tiveram parâmetros e caracteres de similaridade, que se entendem como tamanho mínimo do objeto em agrupamentos de *pixels*, bem como do valor de área (*pixels*) ou janela de varredura empregado para a construção da classificação. Além desses dois fatores principais, também se levou em consideração a cor (tonalidade) e a compacidade (forma) para a geração dos objetos no processo de segmentação, para posteriormente realizar a classificação baseada em objeto (OBIA).

Dessa forma, a segmentação das imagens e por consequência, a análise OBIA foram definidas pelo método de tentativa e erro, onde utilizando-se de ensaios prévios de segmentação, observa-se qual escala resultaria numa maior formação de objetos e, conseqüentemente, em uma análise com maior grau de detalhamento, semelhante ao descrito e utilizado por Ouyang et al. (2011), Gabriel (2013) e Neves (2013), que afirmam não existir critérios pré-estabelecidos ou experiências aprimoradas para a determinação das melhores variáveis e parâmetros para o processo de segmentação de imagens.

Assim, após a realização dos ensaios de segmentação, ficou definido que o ensaio que obteve um maior número de objetos, o que implica em uma maior acurácia para as classes de uso e ocupação do solo, devido ao maior detalhamento e que acabou sendo escolhido como a escala de segmentação para as classificações OBIA em ortomosaico RGB e no ortomosaico em NDVI, foi o ensaio que obteve valor de similaridade (escala) de dez (10), valor de nove (9) para área (*pixels*), valor de 0.75 para cor (tonalidade), valor de 0.25 para compacidade (forma) e gerando um total de 10361 objetos no processo de segmentação dos ortomosaicos.

Os demais ensaios de segmentação, com valores de similaridades inferiores a dez (10), proporcionaram uma ampla confusão entre os grupos de *pixels* das diferentes classes de uso e ocupação do solo, acabando por determinar polígonos

isolados dentro de grandes regiões. Já em consideração aos ensaios de segmentação com valores de similaridade superior a dez (10), certas classes extrapolaram o limite a qual pertenciam, dessa maneira, acabaram por agregar *pixels* de diferentes classes como sendo uma única classe. Característica semelhante também foi observada nos ensaios em que a proporção entre cor e compacidade foi igualmente proporcional (50 % a 50 %), ou onde a proporção para compacidade foi maior, nesses casos certas classes de objetos possuíam *pixels* de tonalidades diferentes da classificação observada.

Os ortomosaicos utilizados no estudo também são detentores da variável textura, característica essa relacionada com os parâmetros de segmentação de cor e compacidade dos objetos e que representa a rugosidade topográfica da superfície dos mesmos, presente principalmente em imagens de alta resolução espacial, podendo dessa forma, ter suas estimativas relativamente transformadas devido à variação vertical de altura da superfície, que conseqüentemente influencia nos dosséis de vegetação, principalmente as de porte arbóreo influenciando assim na qualidade posterior das classificações obtidas.

As classificações baseadas em objeto, resultantes do processo de segmentação (OBIA RGB e OBIA NDVI), foram cruzadas com a verdade terrestre (VT), que consiste no resultado respectivo e a real utilização com relação ao uso e ocupação do solo das APP hídricas da área de estudo, tendo como base para sua elaboração o ortomosaico em RGB, para dessa forma, saber a acurácia de cada classificação com relação ao referencial absoluto de utilização do solo. A classificação com melhor acurácia e validação (exatidão global, índice Kappa e teste estatístico Z), posteriormente foi usada como referencial para a comparação entre as próprias análises, a fim de se obter a correlação existente entre as classificações segmentadas OBIA RGB e OBIA NDVI.

4.4.1 Comparação entre VT e OBIA RGB e validação

Com base no ortomosaico em RGB foi possível a obtenção da VT e a identificação de quatro classes referentes ao uso e ocupação do solo (Tabela 7),

onde é possível observar que a classe mais abrangente da área de estudo corresponde a “vegetação arbórea”, ocorrendo em uma área total de 4,16 ha (69,89 %). A segunda classe em abrangência consiste na ocupação por “vegetação herbácea” com uma área total de 0,90 ha (15,14 %), seguida pelas classes “leito do rio” com 0,64 ha (10,69 %) de área e por fim, a classe “sombras” com uma área total de 0,26 ha (4,28 %).

Tabela 7 - Análise das classes de uso do solo da VT e OBIA RGB.


Classes	Verdade Terrestre (VT)		OBIA RGB	
	Área (ha)	Área (%)	Área (ha)	Área (%)
Leito do Rio	0,64	10,69	0,28	4,62
Sombras	0,26	4,28	0,12	2,05
Vegetação Arbórea	4,16	69,89	4,87	81,73
Vegetação Herbácea	0,90	15,14	0,69	11,60
TOTAL	5,96	100,00	5,96	100,00

A classificação segmentada OBIA RGB apresentou a mesma proporção de ordem de distribuição das classes de uso e ocupação do solo, semelhante a encontrada na VT da APP, com a classe de “vegetação arbórea” como sendo a mais abrangente na classificação com 4,87 ha (81,73 %), seguida pela classe “vegetação herbácea” com 0,69 ha (11,60 %) de área, pela classe “leito do rio” com 0,28 ha (4,62 %) do total e pela classe “sombras” com um total de 0,12 ha (2,05 %) de área. Dessa maneira, fica evidente que praticamente 3/4 da área total de APP hídrica, tanto na VT quanto a classificação OBIA RGB, no trecho de estudo do rio Lavapés, são compostos principalmente por indivíduos de porte arbóreo e estando dentro do que preza a legislação florestal vigente.

Porém há diferenças que podem ser observadas tanto no que se refere a distribuição espacial (Figura 25), quanto na própria proporção de áreas referentes a cada classe de utilização do solo da classificação OBIA RGB com relação a VT das APP hídricas da área de estudo. Sendo a classe “sombras” a que apresentou a

menor variação em área, mas sendo menos da metade do valor correspondente da VT.

Figura 25 - VT (A) e OBIA RGB (B) da APP da área de estudo.



Na matriz de confusão (Tabela 8), obtida do cruzamento referente à cada classe de uso e ocupação do solo da OBIA RGB com a VT, sendo que na diagonal principal tem-se as amostras corretas das classes “leito do rio”, “sombras”, “vegetação arbórea” e “vegetação herbácea”. Com base na matriz de confusão foi possível então obter a exatidão global e o índice Kappa, os erros de omissão e comissão, bem como a validação de Kappa pelo teste estatístico Z da classificação OBIA RGB.

Tabela 8 - Matriz de confusão entre VT e OBIA RGB.

-	Veg. Arb.	Veg. Herb.	Lei. Rio	Sombras	TOTAL	Err. com.	Risc. prod. (%)	Conf. prod. (%)
Veg. Arb.	1514	37	45	33	1629	115	7,06	92,94
Veg. Herb.	45	258	24	44	371	113	30,46	69,54
Lei. Rio	31	50	302	39	422	120	28,44	71,56
Sombras	58	43	53	253	407	154	37,84	62,16
TOTAL	1648	388	424	369	2829	-	-	-
Err. omi.	134	130	122	116	-	-	-	-
Risc. usu. (%)	8,13	33,51	28,77	31,44	-	-	-	-
Conf. usu. (%)	91,87	66,49	71,23	68,56	-	-	-	-
p-valor ($\alpha = 0,05$)	0,00209	0,00589	0,01769	0,00484	-	-	-	-
Var.	0,00218	-	-	-	-	-	-	-
Desv. pad.	0,04672	-	-	-	-	-	-	-
Err. pad.	0,00088	-	-	-	-	-	-	-
Exatidão global (%)	82,26	-	-	-	-	-	-	-
Índice Kappa (%)	70,69	-	-	-	-	-	-	-
Teste Z	15,13	-	-	-	-	-	-	-

Onde: Veg. Arb. é a vegetação arbórea; Veg. Herb. é a vegetação herbácea; Lei. Rio é o leito do rio; Err. omi. são os erros de omissão; Err. com. são os erros de comissão; Risc. usu. é o risco do usuário; Conf. usu. é a confiança do usuário; Risc. prod. é o risco do produtor; Conf. prod. é a confiança do produtor; Var. é a variância da matriz de confusão; Desv. pad. é o desvio padrão da matriz de confusão; e Err. pad. é o erro padrão da matriz de confusão.

A classificação OBIA RGB na APP hídrica da área de estudo obteve uma exatidão global de 82,26 % de acurácia com a VT, obtendo-se dessa forma um valor satisfatório de acurácia por esse índice para imagem de alta resolução, semelhante ao encontrado por Queiroz et al. (2017) que obtiveram 80,00 % ao utilizaram imagem do satélite de alta resolução *RapidEye* para estudo na região central do Rio Grande do Sul. Porém, como a exatidão global utiliza apenas os dados da diagonal principal da matriz de confusão, não contabiliza os erros presentes na classificação, conforme descrito por Neves (2013), em estudo da identificação do uso do solo na região metropolitana de Lisboa, Portugal.

Dessa forma, aplicou-se o índice Kappa, pois o mesmo avalia a exatidão da classificação de imagens, utilizando-se de todos os elementos presentes na matriz de confusão, inclusive os erros. Assim, para a classificação segmentada OBIA RGB foi encontrado um índice Kappa de 70,69 %, que segundo a classificação proposta por Landis e Koch (1977), possui uma qualidade de classificação de imagem intitulada como "Muito boa", sendo interpretado por ter uma concordância substantiva com o referencial da VT.

Resultado semelhante para o valor de Kappa, na ordem de 0,69 foi encontrado por Gabriel (2013) em estudo com ensaios de segmentação e classificação baseada em objeto com 4 níveis de escala e 13 classes de uso, utilizando-se de imagem de alta resolução espacial do satélite *WorldView-2* na freguesia portuguesa de Campo Grande em Lisboa, Portugal, que segundo a autora, foi um valor satisfatório de Kappa no estudo da utilização do solo.


Cohenca e Carvalho (2015) utilizando a classificação OBIA em imagens do satélite *Landsat-8*, nos municípios de Passo de Torres e Balneário Gaivota em Santa Catarina e obtiveram valor de índice Kappa de 0,57, que segundo os autores foi considerado como "bom", os autores ainda avaliam que a metodologia da OBIA é altamente dependente do intérprete para a determinação das diferenças existentes entre as classes e que devido a menor resolução espacial do sensor, as diferenças espectrais dos objetos foram mais utilizadas no processo de segmentação do que a própria similaridade e compacidade dos objetos.

A avaliação da significância estatística obtida pelo índice Kappa da OBIA RGB com a VT como referência, foi calculado o teste estatístico de significância Z,

seguindo as formulações apresentadas por Congalton e Green (2019), obtendo-se um resultado de 15,13, esse valor foi superior ao Z tabelado e proposto pelos autores, que é de 1,96 com intervalo de confiança de 0,05, dessa forma, a classificação OBIA RGB empregada é estatisticamente mais significativa do que uma classificação aleatória, corroborando a qualidade da classificação utilizada bem como o uso de imagens com elevada resolução espacial coletadas por drone para esse tipo de análise.

Os erros de omissão e comissão presentes na classificação OBIA RGB mostram que 29,31 % da área foram mapeadas de maneira equivocada pelo algoritmo de segmentação do SPRING. Na Figura 26, tem-se uma representação gráfica dos erros de omissão na classificação OBIA RGB.

Figura 26 - Erros de omissão da matriz VT e OBIA RGB.



A classe que obteve uma menor quantidade de *pixels* classificados erroneamente foi a de “sombras” totalizando em 116, porém foi a classe que obteve uma menor confiança do usuário com 68,56 %, valor esse similar ao da classe “vegetação herbácea”, que obteve 66,49 % de confiança, com 130 *pixels* classificados de forma errada pelo classificador.

Juntas essas classes são as que oferecem os maiores riscos na classificação OBIA RGB para o usuário, com 33,51 % para “vegetação herbácea”, principalmente

devido a essa classe ocorrer mais dispersa e em maciços menores, gerando maior confusão na análise, e 31,44 % de risco ao usuário para "sombras". Queiroz et al. (2017), relataram valor semelhante ao encontrado para a vegetação herbácea, em áreas de agricultura, com 64,67 % de confiança do usuário para essa classe, que possui um comportamento espectral semelhante ao encontrado para a classe "vegetação herbácea".

Já a classe que obteve uma maior quantidade de *pixels* analisados de forma correta na classificação OBIA RGB foi a de "vegetação arbórea" com um total de 1514, sendo essa classe também a de maior confiança do usuário com 91,87 %, seguida pela classe "leito do rio" com 302 pixels corretamente classificados e uma confiança do usuário de 71,23 %.


Consequentemente, ambas as classes foram as que tiveram os menores riscos ao usuário, com grande destaque para a classe "vegetação arbórea" com 8,13 %, esse valor elevado se deve principalmente pelo fato dessa classe ocorrer em um gradiente elevado e maciço, seguida pela classe "leito do rio" com 28,77 % de risco ao usuário. Ferreira, Dantas e Moraes (2007) encontraram uma taxa de risco ao usuário semelhante de 7 % na classificação de uma imagem do satélite CBERS-2 em estudo sobre fragmentos de mata no município de Lavras-MG para a categoria denominada "floresta", que possui semelhança espectral com a classe "vegetação arbórea" analisada.

Com relação aos erros de comissão, as classes que obtiveram uma menor quantidade de *pixels* analisados erroneamente pelo algoritmo de segmentação foram "vegetação herbácea" e "vegetação arbórea", com valores, respectivamente, de 113 e 115, com grande destaque para a última, que obteve também a maior confiança do produtor com 92,94 e, consequentemente, a menor proporção de risco ao produtor com 7,06 %.

Resultados semelhantes para a confiança do produtor foram encontrados por Ferreira, Dantas e Moraes (2007) para a classe "floresta" com 93,2 % e por Queiroz et al. (2017) que obtiveram 94,60 % para a classe "floresta nativa", devido a semelhança espectral das classificações propostas em ambos os estudos e semelhante ao encontrado para a confiança do usuário no erro de comissão. Na

Figura 27, tem-se uma representação gráfica dos erros de comissão na classificação OBIA RGB.

Figura 27 - Erros de comissão da matriz VT e OBIA RGB.



A classe “leito do rio” teve 120 *pixels* analisados de forma equivocada pelo algoritmo de segmentação e teve um valor de confiança do produtor de 71,56 % e de risco do produtor de 28,44 %, valores bem próximos aos obtidos pela classe “vegetação herbácea”, que teve 69,54 % para confiança do produtor e 30,46 % para risco do produtor. Queiroz et al. (2017), obtiveram valor semelhante ao encontrado para a classe “vegetação herbácea”, para a classificação “campo” com 77,4 % de confiança do produtor, ao estudarem os usos da terra utilizando de imagens do satélite *RapidEye*, por ser composta praticamente por gramíneas, a classificação usada pelos autores possui semelhança a vegetação herbácea encontrada na APP hídrica da área de estudo.

Por fim, a classe “sombras” foi a que teve um maior número de *pixels* classificados errados em outras classes totalizando em 154, e dessa maneira, tendo a menor confiança do produtor de 62,16 % e o maior risco do produtor de 37,84 %, sendo, portanto, a classe que obteve maior confusão pelo algoritmo do SPRING no momento da segmentação e posterior classificação OBIA RGB. Proporção semelhante de confiança e risco do produtor para a classificação “sombra” foi

encontrada por Neves (2013), que obteve 60,16 % de confiança e 39,84 % de risco do produtor para a mesma classe, devido a sua confusão por semelhança nos objetos formados com outros elementos da paisagem analisados pela autora.

Com base nos valores obtidos pela exatidão global, índice Kappa, teste Z e dos erros de omissão e comissão da matriz de confusão fica elucidado, que os resultados obtidos pela classificação OBIA RGB, utilizando-se de drone como plataforma para obtenção de imagens com elevada resolução espacial, foram satisfatórios quando comparados com a verdade absoluta da APP hídrica da área de estudo (VT) e possuindo, dessa maneira, potencial para o mapeamento temático de classificação da utilização do solo.

4.4.2 Comparação entre VT e OBIA NDVI e validação


Utilizando-se o ortomosaico do índice radiométrico NDVI, que emprega os comprimentos de onda do vermelho e infravermelho próximo como base para sua elaboração, e que consistem nos comprimentos de onda mais refletidos pelas plantas em geral, facilitando a identificação das mesmas nas imagens geradas e obtidas no período de seca. Com base nessa característica, foi possível gerar a classificação OBIA NDVI com quatro classes de uso e ocupação do solo (Tabela 9), para a sua comparação com a VT da APP hídrica.

Tabela 9 - Análise das classes de uso do solo da VT e OBIA NDVI.

Classes	Verdade Terrestre (VT)		OBIA NDVI	
	Área (ha)	Área (%)	Área (ha)	Área (%)
Leito do Rio	0,64	10,69	0,51	8,62
Sombras	0,26	4,28	0,11	1,76
Vegetação Arbórea	4,16	69,89	4,81	80,74
Vegetação Herbácea	0,90	15,14	0,53	8,88
TOTAL	5,96	100,00	5,96	100,00

A classificação segmentada OBIA NDVI (Figura 28) apresentou a mesma proporção de ordem referente a distribuição das classes de uso e ocupação do solo que a VT da APP hídrica, com a classe “vegetação arbórea” como sendo a mais abrangente na classificação com 4,81 ha (80,74 %) de área, seguida pela classe “vegetação herbácea” com 0,53 ha (8,88 %) de área, pela classe “leito do rio” com 0,51 ha (8,62 %) do total e pela classe “sombras” com um total de 0,11 ha (1,76 %) de área, porém é possível notar diferenças com a VT.

Figura 28 - VT (A) e OBIA NDVI (B) da APP da área de estudo.



Com base na matriz de confusão (Tabela 10) foi possível obter então a exatidão global e o índice Kappa, os erros de omissão e comissão, bem como a validação de Kappa pelo teste estatístico Z da classificação OBIA NDVI.

Tabela 10 - Matriz de confusão entre VT e OBIA NDVI.

-	Veg. Arb.	Veg. Herb.	Lei. Rio	Sombras	TOTAL	Err. com.	Risc. prod. (%)	Conf. prod. (%)
Veg. Arb.	2443	49	45	39	2576	133	5,16	94,84
Veg. Herb.	28	264	48	54	394	130	32,99	67,01
Lei. Rio	33	41	414	47	535	121	22,62	77,38
Sombras	47	59	55	239	400	161	40,25	59,75
TOTAL	2551	413	562	379	3905	-	-	-
Err. omi.	108	149	148	140	-	-	-	-
Risc. usu. (%)	4,23	36,08	26,33	36,94	-	-	-	-
Conf. usu. (%)	95,77	63,92	73,67	63,06	-	-	-	-
p-valor ($\alpha = 0,05$)	0,00154	0,00969	0,00259	0,00876	-	-	-	-
Var.	0,00139	-	-	-	-	-	-	-
Desv. pad.	0,03730	-	-	-	-	-	-	-
Err. pad.	0,00060	-	-	-	-	-	-	-
Exatidão global (%)	86,04	-	-	-	-	-	-	-
Índice Kappa (%)	73,60	-	-	-	-	-	-	-
Teste Z	19,73	-	-	-	-	-	-	-

Onde: Veg. Arb. é a vegetação arbórea; Veg. Herb. é a vegetação herbácea; Lei. Rio é o leito do rio; Err. omi. são os erros de omissão; Err. com. são os erros de comissão; Risc. usu. é o risco do usuário; Conf. usu. é a confiança do usuário; Risc. prod. é o risco do produtor; Conf. prod. é a confiança do produtor; Var. é a variância da matriz de confusão; Desv. pad. é o desvio padrão da matriz de confusão; e Err. pad. é o erro padrão da matriz de confusão.

A classificação OBIA NDVI na APP hídrica da área de estudo obteve uma exatidão global de 86,04 % de acurácia com a VT, obtendo-se dessa forma um valor muito bom de exatidão, ao se utilizar de um índice de vegetação, que demonstra o comportamento espectral de alvos bióticos (vegetação) e oriundo de imagens de alta resolução espacial obtidas por drone.

Resultado semelhante para a exatidão global, utilizando-se de imagens de alta resolução foi encontrado por Gabriel (2013) com 88,80 % para um ensaio de segmentação de nível dois e com quatro classes de cobertura do solo, na região metropolitana de Lisboa, Portugal e utilizando imagens do satélite *WorldView-2*. Neves (2013) também utilizando-se de imagens de alta resolução do mesmo satélite, para as freguesias portuguesas de Ameixoeira, Carnide, Charneca, Lumiar, Odivelas e Olival de Basto na região de Lisboa, Portugal, obteve exatidão de 77,59 % para classificação OBIA com sete classes de utilização da terra.

Como a exatidão global não leva em consideração em seu cálculo os elementos marginais (erros) da matriz de confusão, foi empregado também o índice Kappa, que utiliza desses elementos para avaliação da acurácia do mapeamento e obtendo-se assim, um valor de 73,60 % para a classificação OBIA NDVI, sendo enquadrada pela classificação proposta por Landis e Koch (1977), como tendo uma qualidade de classificação de imagem "Muito boa" e tendo como interpretação do resultado, uma concordância substantiva com o referencial da VT (verdade absoluta) da APP hídrica da área estudo.


Valor similar ao resultado de índice Kappa, foi encontrado por Gabriel (2013) com 75,2 % em classificação segmentada OBIA de nível 2 e com quatro classes de utilização do solo, similar ao do estudo, em imagens de satélite de alta resolução espacial na freguesia portuguesa de Campo Grande em Lisboa, Portugal, e que segundo a autora, resultou em uma boa classificação.

Queiroz et al. (2017) em estudo de avaliação de classificações de uso do solo na região central do Rio Grande do Sul por meio de imagens do satélite *RapidEye*, obtiveram valor Kappa de 73,00 % para a classificação empregada, classificando o resultado como muito bom e que proporcionou uma acurácia satisfatória no mapeamento do padrão de utilização da terra.

Para a avaliação da significância estatística obtida pelo índice Kappa da OBIA NDVI, tendo a VT como referência, foi calculado então o teste de significância estatística Z, conforme o proposto por Congalton e Green (2019), obtendo-se um resultado de 19,73. Esse valor obtido foi superior ao Z tabelado e proposto pelos autores de 1,96 com um intervalo de confiança de 0,05 (5 %), assim, a classificação OBIA NDVI empregada no estudo é estatisticamente mais significativa do que uma classificação gerada aleatoriamente, dessa forma, corroborando com a qualidade da classificação utilizada, tendo como base o índice radiométrico NDVI, que utiliza os comprimentos de onda refletidos pela vegetação (vermelho do espectro visível e o infravermelho próximo) para a sua elaboração, bem como a utilização de imagens com alta resolução espacial obtidas por meio de drone para a avaliação do uso e ocupação do solo.

Os erros de omissão e comissão encontrados na classificação segmentada OBIA NDVI, demonstram que 26,40 % da área de APP hídrica, foram mapeadas de maneira inapropriada pelo algoritmo no processo de segmentação do SPRING. Na Figura 29, tem-se uma representação gráfica dos erros de omissão na classificação OBIA NDVI.

Figura 29 - Erros de omissão da matriz VT e OBIA NDVI.



A classe que obteve uma menor quantidade de *pixels* classificados erroneamente na classificação segmentada OBIA NDVI foi a de “vegetação arbórea”, totalizando em 108, e também foi a classe que obteve a maior confiança do usuário com 95,77 % com 2443 *pixels* classificados assertivamente, e consequentemente, obtendo também o menor risco ao usuário, com apenas 4,23 % de erros de omissão.

Resultado bem semelhante ao de vegetação arbórea, para confiança e risco do usuário foi encontrado por Queiroz et al. (2017), onde os autores trabalhando com mapeamento da utilização do solo com imagens de elevada resolução espacial, obtiveram para a classe “floresta nativa” 95,90 % de confiança do usuário e 4,10 % de risco para o usuário, com poucas amostras sendo incluídas erroneamente para essa classe na avaliação da acurácia do mapeamento.


Em sequência, veio a classe “leito do rio” com 73,67 % de confiança do usuário e com 26,33 % de risco ao usuário, totalizando em 148 *pixels* classificadas de maneira errônea na amostragem da classificação e 414 classificados de maneira assertiva. Esse valor e a segunda posição com relação aos erros de omissão, se deve ao fato do NDVI obter um bom destaque para alvos abióticos (rios e corpos d’água em geral), sendo dessa maneira um índice muito bom tanto para classificar formas de vegetação, bem como corpos d’água. Queiroz et al. (2017) para a classe “água”, que possui um comportamento espectral semelhante a classificação “leito do rio”, encontrou valor de 75,00 % para confiança do usuário e 25,00 % de erros (risco do usuário).

As classes “vegetação herbácea” e “sombras” obtiveram valores de semelhantes com relação aos erros de omissão, tendo a classe “vegetação herbácea” 149 *pixels* classificados erroneamente e 264 *pixels* corretamente analisados, dessa forma, com 63,92 % de confiança do usuário e 36,08 % de risco ao usuário, enquanto que para a classe “sombras” com 140 *pixels* mostrados de maneira incorreta e 239 corretos, foi encontrado para confiança do usuário 63,06 % de acertos e para risco do usuário 36,94 % de erros. Gabriel (2013), utilizando da classificação OBIA em imagens de alta resolução de satélite, obteve um valor de confiança do usuário para a classe “vegetação herbácea” de 63,00 % (acertos) e de risco do usuário de 37,00 % (erros), valores bem próximos aos encontrados no

estudo. Enquanto que Neves (2013), para a classe “sombra” em imagens do satélite *WorldView-2*, encontrou 68,78 % de confiança do usuário e 31,22 % de risco ao usuário por omissão.

Com relação aos erros de comissão, a classe que obteve a maior confiança do produtor foi a “vegetação arbórea”, com 94,84 % de acertos e 2443 *pixels* classificados de maneira correta e que, conseqüentemente, obteve o menor risco do produtor com 5,16 % de erros e 133 *pixels* amostrados incorretamente. Na Figura 30, tem-se uma representação gráfica dos erros de comissão na classificação OBIA NDVI.

Figura 30 - Erros de comissão da matriz VT e OBIA NDVI.



Ferreira, Dantas e Moraes (2007), em estudo sobre fragmentos de mata nativa no município de Lavras-MG e utilizando de imagens do satélite CBERS-2 obtiveram para a categoria denominada “floresta” valor de confiança do produtor de 93 % de acertos e risco do produtor de 7 % de erros de comissão, resultado esse encontrado pelos autores que é similar ao encontrado para a APP da área de estudo, devido a semelhança espectral da classificação “floresta” dos autores, com a classe “vegetação arbórea” analisada no estudo.

A segunda classe com relação a menor proporção de erros de comissão foi a “leito do rio” com 77,38 % de confiança do produtor e 22,62 % de riscos ao produtor, obtendo na amostragem 414 *pixels* corretamente assinalados e 121 *pixels* classificados de maneira incorreta. Valor próximo ao encontrado para a classe “leito do rio”, foi observado por Neves (2013), que para uma classe de comportamento espectral semelhante ao utilizado no estudo, denominada “corpos d’água” em classificação OBIA em imagens de alta resolução de satélite, obteve valor de confiança do produtor de 83,84 % (acertos) e de risco ao produtor de 16,16 % (erros).

Em sequência, tem-se a classe “vegetação herbácea” com 67,01 % de confiança do produtor, com 264 *pixels* acertados e com 32,99 % de risco do produtor, com um total de 130 *pixels* amostrados incorretamente. Resultado similar ao encontrado para essa classe, foi também observado por Queiroz et al. (2017) que utilizando de imagens do satélite *RapidEye* para o mapeamento de utilização da terra, encontraram para a classe “campo”, composta basicamente por gramíneas e portanto, apresentando comportamento semelhante ao da classe “vegetação herbácea” do estudo, obtiveram 69,40 % de acertos pela confiança do produtor e 30,60 % de erros pelo risco do produtor.

E por fim, a classe “sombras” que apresentou 59,75 % (239 *pixels* corretos) de confiança do produtor e 40,25 % (161 *pixels* incorretos) de risco do produtor, sendo essa classe, semelhante ao encontrado para os erros de omissão, a classe que apresentou a maior confusão de *pixels* na segmentação do algoritmo do SPRING na classificação OBIA NDVI, levando a esse erro mais acentuado. Gabriel (2013), encontrou valores similares para a classe “sombra” em classificação segmentada OBIA baseada em imagens do satélite *WorldView-2*, obtendo 57 % de confiança do produtor e 43 % de riscos ao produtor, sendo considerada pela autora como uma classe de difícil separação espectral de outros alvos devido a efeito de ambiguidade gerado.

Dessa forma, tendo como base os valores obtidos pela exatidão global, índice Kappa, teste estatístico Z e dos erros de omissão e comissão da matriz de confusão, demonstra que os resultados obtidos pela classificação OBIA NDVI, utilizando-se do ortomosaico do índice radiométrico NDVI, que utiliza a resposta espectral das

plantas pela reflexão dos espectros de radiação referentes ao vermelho visível e do infravermelho próximo e obtido no período de seca do município de Botucatu-SP, que facilita a diferenciação espectral das forma de vegetação arbórea e herbácea, além de drone como plataforma para obtenção de imagens com elevada resolução espacial, foram muito bons quando comparados com a verdade absoluta da APP hídrica da área de estudo (VT), possuindo acurácia temática superior a classificação OBIA RGB e, dessa maneira, uma boa empregabilidade da classificação OBIA baseada no índice radiométrico do NDVI, com grande potencial para o mapear os padrões de utilização do solo.

4.4.3 Comparação entre OBIA RGB e OBIA NDVI e validação


Com base nos resultados obtidos pelas classificações OBIA RGB e OBIA NDVI, foi possível então comparar as duas classificações e observar as correlações entre ambas (Tabela 11). Como demonstrado anteriormente, a classificação OBIA NDVI obteve valor de acurácia temática tanto pela exatidão global quanto pelo índice Kappa superiores ao da OBIA RGB, principalmente devido as características do índice radiométrico NDVI em permitir a visualização do comportamento espectral das formas de vegetação (alvos bióticos), bem como do leito do rio Lavapés (alvo abiótico), dessa maneira, o mapa da classificação OBIA NDVI foi utilizado como referencial para a análise comparativa das classificações.

Tabela 11 - Análise das classes de uso do solo da OBIA RGB e OBIA NDVI.

Classes	OBIA RGB		OBIA NDVI	
	Área (ha)	Área (%)	Área (ha)	Área (%)
Leito do Rio	0,28	4,62	0,51	8,62
Sombras	0,12	2,05	0,11	1,76
Vegetação Arbórea	4,87	81,73	4,81	80,74
Vegetação Herbácea	0,69	11,60	0,53	8,88
TOTAL	5,96	100,00	5,96	100,00

As duas classificações (Figura 31), apresentaram proporções semelhantes referente a distribuição das classes de uso e ocupação do solo que na APP hídrica da área de estudo. Com a classe "vegetação arbórea" sendo a mais abrangente, seguida pelas classes "vegetação herbácea", "leito do rio" e "sombras". Sendo a principal diferença com relação a classe "leito do rio", devido a característica do NDVI em identificar alvos abióticos, que proporcionou melhor detalhamento dessa classe pela OBIA NDVI, apresentando resultado quase que o dobro da OBIA RGB.

Figura 31 - OBIA RGB (A) e OBIA NDVI (B) da APP da área de estudo.



Com base na matriz de confusão (Tabela 12) foi possível obter então a exatidão global e o índice Kappa, os erros de omissão e comissão, bem como a validação de Kappa pelo teste Z da correlação entre OBIA RGB e OBIA NDVI.

Tabela 12 - Matriz de confusão entre OBIA RGB e OBIA NDVI.

-	Veg. Arb.	Veg. Herb.	Lei. Rio	Sombras	TOTAL	Err. com.	Risc. prod. (%)	Conf. prod. (%)
Veg. Arb.	2473	28	34	23	2558	85	3,32	96,68
Veg. Herb.	61	388	23	31	503	115	22,86	77,14
Lei. Rio	24	34	475	17	550	75	13,64	86,36
Sombras	35	19	28	269	351	82	23,36	76,64
TOTAL	2593	469	560	340	3962	-	-	-
Err. omi.	120	81	85	71	-	-	-	-
Risc. usu. (%)	4,63	17,27	15,18	20,88	-	-	-	-
Conf. usu. (%)	95,37	82,73	84,82	79,12	-	-	-	-
p-valor ($\alpha = 0,05$)	0,00189	0,00385	0,00245	0,00541	-	-	-	-
Var.	0,00046	-	-	-	-	-	-	-
Desv. pad.	0,02152	-	-	-	-	-	-	-
Err. pad.	0,00034	-	-	-	-	-	-	-
Exatidão global (%)	90,99	-	-	-	-	-	-	-
Índice Kappa (%)	83,16	-	-	-	-	-	-	-
Teste Z	38,64	-	-	-	-	-	-	-

Onde: Veg. Arb. é a vegetação arbórea; Veg. Herb. é a vegetação herbácea; Lei. Rio é o leito do rio; Err. omi. são os erros de omissão; Err. com. são os erros de comissão; Risc. usu. é o risco do usuário; Conf. usu. é a confiança do usuário; Risc. prod. é o risco do produtor; Conf. prod. é a confiança do produtor; Var. é a variância da matriz de confusão; Desv. pad. é o desvio padrão da matriz de confusão; e Err. pad. é o erro padrão da matriz de confusão.

A comparação da classificação OBIA RGB com a OBIA NDVI na APP hídrica da área de estudo obteve uma exatidão global de 90,99 % de acurácia obtendo-se dessa forma um valor excelente de exatidão, ao se comparar o mapa em RGB, tendo como referência um mapa com base no índice radiométrico NDVI, que demonstra principalmente o comportamento espectral de alvos bióticos (vegetação) e oriundo de imagens com elevada resolução espacial coletadas por drone.

Neves (2013) em seu estudo com segmentação pela metodologia OBIA em imagens alta resolução do satélite *WorldView-2*, obteve valor de exatidão global para um ensaio de segmentação de nível e quatro classes de uso do solo de 88,80 % de acurácia, valor bem próximo ao obtido para a correlação da OBIA RGB com a OBIA NDVI para a APP hídrica da área de estudo. Resultados semelhantes ao encontrado no estudo, foram obtidos por Leite (2019), em estudo com diferentes índices de vegetação para a discriminação do uso da terra em bacia hidrográfica, utilizando de imagens fusionadas do satélite *Sentinel-2* de 10 m de resolução, em que a autora obteve exatidão global de 87,26 % para o mapa formado pelos índices NDBI-NDVI-NDWI e 85,21 % de acurácia por exatidão global para o mapa NDBI-NDI45-NDWI.

Devido a exatidão global não levar em seu cálculo os erros presentes na comparação da classificação, foi calculado também o índice Kappa para OBIA RGB tendo OBIA NDVI como referência, semelhante ao realizado com as classificações e a VT da área de estudo. Dessa forma, obtendo-se um valor de Kappa de 83,16 % de acurácia para a correlação entre OBIA RGB e OBIA NDVI, que segundo a classificação proposta por Landis e Koch (1977), possui uma qualidade de classificação de imagem "Excelente", e sendo interpretada por ter uma concordância quase perfeita com o referencial analisado (OBIA NDVI) da APP hídrica da área estudo.

Pirolí e Campos (2010), utilizando-se de classificação supervisionada pela máxima verossimilhança em imagens fusionadas do satélite Landsat-7, obtiveram valor de índice Kappa de 87,00 % de acurácia, resultado próximo ao obtido no estudo e no mesmo enquadramento proposto por Landis e Koch (1977), e que segundo os autores, forneceu uma confiabilidade muito boa para o mapeamento do padrão de utilização da terra na microbacia.

Valor similar ao resultado de índice Kappa, foi encontrado por Leite (2019), onde utilizando-se de diferentes índices radiométricos para a classificação da cobertura do solo, obteve índice Kappa de 82,00 % para o mapa formado pelos índices NDBI-NDI45-NDWI e 84,00 % de acurácia por Kappa para o mapa NDBI-NDVI-NDWI. Para a autora, esses resultados evidenciaram o bom desempenho e a eficiência das associações e a própria utilização dos índices de vegetação para discriminação de alvos e para a classificação, podendo ser comparados as classificações convencionais que se baseiam em imagens em RGB.


Segundo Rodrigues (2015) e Rodrigues et al. (2016) em resultados de classificações com elevado valor de acurácia temática, como o obtido pela OBIA RGB ao ser comparada com a OBIA NDVI pelo índice Kappa de 83,16 % e classificação "Excelente", isso indica que fica impossível dissociar esses resultados das rotinas estatísticas e dos demais tipos de erros, como o posicional e consequentemente o temático, uma vez que a precisão é considerada como sendo uma grandeza que mede a dispersão e o erro dos dados referentes as diferentes classificações.

Para a avaliação da significância estatística do valor obtido pelo índice Kappa da OBIA RGB com a OBIA NDVI como sendo a referência, foi calculado, dessa forma, o teste estatístico de significância Z, seguindo as formulações propostas e apresentadas por Congalton e Green (2019), obtendo-se assim, um resultado de 38,64, esse valor encontrado foi superior ao Z tabelado e proposto pelos autores, que é de 1,96 com um intervalo de confiança de 0,05 (5 %), assim, a comparação da classificação OBIA RGB com a OBIA NDVI como sendo a referência, devido as suas propriedades espectrais e por ser baseada no índice radiométrico NDVI, é estatisticamente mais significativa do que uma classificação gerada de forma aleatória, evidenciando a qualidade das classificações empregadas no estudo das APP hídricas da área de estudo, sendo a classificação usada como referência fundamentada em um índice de vegetação, bem como da utilização de imagens com elevada resolução espacial e coletadas por drone para esse tipo de análise ambiental.

Os erros de omissão e comissão presentes na comparação das classificações OBIA RGB e OBIA NDVI, mostram que 16,84 % da área de estudo foram mapeadas

de maneira inapropriada pelo algoritmo do SPRING no processo de segmentação das imagens. Na Figura 32, tem-se uma representação gráfica dos erros de omissão na correlação de OBIA RGB e OBIA NDVI.

Figura 32 - Erros de omissão da matriz OBIA RGB e OBIA NDVI.



A classe que obteve a melhor confiança do usuário na comparação das classificações segmentadas OBIA RGB e OBIA NDVI para a APP hídrica da área de estudo foi a de “vegetação arbórea” com 95,37 % de assertividade e com 2473 *pixels* amostrados corretamente e consequentemente, também foi a com o menor risco ao usuário com 4,63 % e 120 *pixels* erroneamente amostrados. Esses valores obtidos, demonstram que a classe “vegetação arbórea” foi a que teve menor confusão com *pixels* de outras classes devido a semelhanças causadas por ambiguidade espectral.

Resultados semelhantes de confiança e erro do usuário, foram encontrados por Leite (2019), que obteve para a classe “mata”, em classificação baseada nos índices radiométricos NDBI-NDI45-NDWI, valores de 94,17 % de confiança do usuário e 5,83 % de risco para o usuário, e para a classificação baseada nos índices NDBI-NDVI-NDWI encontrou valor de 93,95 % para confiança do usuário e 6,05 % de risco ao usuário, sendo que para ambas as classificações, a classe “mata” foi a que obteve melhor acerto (confiança do usuário).

Em seguida veio a classe “leito do rio”, como a segunda melhor em confiança e risco do usuário para a comparação entre a OBIA RGB e OBIA NDVI, com 84,82 % de confiança do usuário e 475 *pixels* amostrados corretamente, e consequentemente com 15,18 % risco ao usuário na classificação, com um total de 85 *pixels* amostrados inadequadamente e caracterizando os erros de omissão para essa classe. Neves (2013) obteve resultado semelhante ao do estudo, para a classe denominada “corpos d’água” com 88,33 % de confiança do usuário e 11,67 % de risco do usuário, que possui comportamento espectral semelhante a classe “leito do rio”, em estudo utilizando de classificação baseada em objeto em imagem do satélite *WorldView-2*, para identificar a utilização da terra em área urbana de Lisboa, Portugal.

Com um valor muito próximo ao leito do rio na comparação entre as duas classificações, tem-se a classe “vegetação herbácea” com 82,73 % de confiança do usuário e 388 *pixels* analisados acertadamente e dessa forma, obtendo-se um erro de omissão com 17,27 % de risco ao usuário para essa classe, tendo um total de 81 *pixels* de outras classes analisados de maneira errada pelo algoritmo do SIG. Resultado similar foi observado por Queiroz et al. (2017) em estudo com imagens de alta resolução espacial do satélite *RapidEye*, com a classe de comportamento espectral similar a de vegetação herbácea, denominada pelos autores como “campo”, que possui grande predomínio de gramíneas em geral e apresentando valor de confiança do usuário de 75,00 % e risco ao usuário de 25,00 % por erros de omissão dessa classe.


E a classe que obteve o menor valor referente a confiança do usuário na comparação entre as classificações OBIA RGB e OBIA NDVI na APP hídrica da área de estudo foi a de “sombras”, com 79,12 % de confiança e 269 *pixels* corretamente amostrados, e tendo como risco do usuário 20,88 % por erros de omissão com 71 *pixels* assinalados de maneira inapropriada na amostra. Demonstrando que de maneira inversa ao encontrado para a classe “vegetação arbórea”, foi a que teve a maior confusão por *pixels* de outras classes, principalmente devido à ambiguidade espectral.

Valor semelhante quanto a proporção de confiança e erro do usuário foi encontrado por Gabriel (2013), que obteve para uma área de perímetro urbano do

município de Lisboa, Portugal, na classificação do uso do solo em imagens de satélite com elevada resolução espacial, para a classe “sombra” valor de 79,00 % de confiança do usuário e 21,00 % de risco do usuário por erros de omissão, para uma classificação segmentada OBIA de nível quatro e com treze classes de utilização da terra.

Já em relação aos erros de comissão, a classe que obteve a maior confiança do produtor foi a de “vegetação arbórea”, com 96,68 % de acertos e com um total de 2473 *pixels* classificados de maneira acertada e que, conseqüentemente, obteve também o menor risco do produtor com 3,32 % de erros por comissão e com 85 *pixels* amostrados inadequadamente pelo algoritmo do SPRING. Na Figura 33, tem-se uma representação gráfica dos erros de comissão obtidos na comparação das classificações OBIA RGB e OBIA NDVI.

Figura 33 - Erros de comissão da matriz OBIA RGB e OBIA NDVI.



Leite (2019) em estudo com diferentes metodologias para classificações de usos do solo empregando índices de vegetação, obteve para a classe “mata” valor de confiança do produtor de 88,06 % e 11,94 % de risco do produtor por erros de comissão para a classificação NDBI-NDI45-NDWI, e 87,04 % de confiança do produtor com 12,96 % de risco ao produtor por comissão para a classificação NDBI-NDVI-NDWI. Resultados esses que apesar de inferiores aos encontrados para a

classe “vegetação arbórea” da área de estudo, são próximos e identificam uma classe de ocupação do solo com um comportamento espectral semelhante ao da classificação empregada no estudo.

Em segundo lugar com relação a confiança do produtor tem-se a classe “leito do rio”, com 86,36 % e com um total de 475 *pixels* corretamente amostrados, já os erros de comissão dessa classe, configuram um total de 13,64 % com 75 *pixels* analisados de maneira incorreta na comparação entre OBIA RGB e OBIA NDVI. Esse resultado encontrado foi inferior, porém próximo ao observado por Gabriel (2013), que utilizando-se da classificação segmentada na identificação de treze classes para o mapeamento de utilização do solo, em imagens de satélite de elevada resolução no perímetro urbano de Lisboa, Portugal, obteve para a classe “água” confiança do produtor de 91,00 % e risco do produtor de 9,00 % por erros de comissão dos pixels observados.

As classes “vegetação herbácea” e “sombras”, obtiveram valores próximos de confiança e risco do produtor na correlação das classificações OBIA RGB e OBIA NDVI, sendo as classes que obtiveram as maiores confusões causadas por *pixels* observados. A classe “vegetação herbácea” com 77,14 % de confiança do usuário e 388 *pixels* analisados corretamente e 22,86 % de risco do usuário com um total de 115 *pixels* amostrados erroneamente, já para a classe “sombras”, foi encontrada confiança do produtor de 76,64 % com 269 *pixels* e risco do produtor de 23,36 % com 82 *pixels*.

Resultado próximo ao encontrado no estudo para a vegetação herbácea, foi observado por Leite (2019), que ao analisar uma classe de comportamento espectral semelhante e composta exclusivamente por gramíneas intitulada de “pasto” na classificação NDBI-NDI45-NDWI, obteve 72,55 % de confiança do produtor e 27,45 % de risco ao produtor por erros de comissão, sendo essa classe semelhante a “vegetação herbácea” uma das que mais tiveram confusão de *pixels* observados na classificação proposta pela a autora, devido a ambiguidade de espectro causada por essas classes.

Gabriel (2013) em classificação baseada em objeto de nível 4 e com treze classes de utilização da terra, com uso de imagens do satélite *WorldView-2*, obteve resultados semelhante a sombras, para a classe intitulada “sombra” com 80,00 % de

confiança do produtor e consequentemente 20,00 % de risco ao produtor por erros de comissão. Segundo a mesma autora, essa classe por se tratar da projeção da sombra de outros elementos da paisagem, tende a ter maior confusão de *pixels* por semelhanças espectrais conforme maior for o número de classes empregadas na classificação.

Todos os erros observados nas matrizes, são oriundos da confusão entre os *pixels* amostrados das diferentes classes presentes no mapeamento. As confusões nas interpretações decorrentes das semelhanças entre as classes mais afetadas pelos erros de omissão e comissão, além da presença do fator referente a ambiguidade espectral, a qual também acaba sendo afetada pelo relevo acidentado causado pela diferença entre os *pixels* da imagem, onde as suas referentes classes se encontram. De acordo com Meneses e Almeida (2012) e Rodrigues (2015), as imagens obtidas por sensoriamento remoto possuem uma interação macroscópica, que é a relação da REM com os objetos, dessa forma, a intensidade que um objeto reflete a REM está relacionada com a razão de tamanho do comprimento de onda e também com a textura superficial dos objetos (rugosidade e relevo das imagens).

A rugosidade e a flutuação topográfica dos alvos terrestres, favorecem a dispersão da REM, com o fenômeno de reflexão, espalhando assim os raios eletromagnéticos em todas as direções devido à superfície ser mais rugosa, uma vez que na faixa do comprimento de onda visível (0,380 a 0,740 μm) e do infravermelho-próximo (0,725 a 1,10 μm), a onda emitida é bem inferior ao tamanho das amplitudes de variação da altura superficial do solo. Dessa forma, ao se interpretar uma imagem de alta resolução, fica possível separar classe de vegetação arbórea, de uma com vegetação herbácea e até mesmo uma área sombreada, apesar de espectralmente estas classes possuam algum tipo de similaridade, no entanto, são confundidas pelo classificador da OBIA.

E apesar do processo de segmentação ter uma porcentagem de erro agregado em relação a verdade terrestre (NDVI), o coeficiente Kappa apresentou resultado "Excelente" (0,8236), dentro dos valores propostos por Landis e Koch (1977) que permitem esse enquadramento, dessa forma, evidenciando que a OBIA apresenta potencial para apresentar uma classificação com alto grau de exatidão e confiabilidade na classificação, podendo-se equiparar aos dados obtidos pelo NDVI,

que é um parâmetro radiométrico e representa aspectos biológicos, físicos e químicos das plantas, como a atividade fotossintética, área foliar, acúmulo de biomassa, entre outros.

Outro aspecto importante e observado foi que a elevada resolução dos ortomosaicos obtidos com sensor embarcado em drone e com um GSD de 3,5 cm, contribuiu de forma muito significativa para o valor elevado do índice de exatidão global e índice Kappa encontrados, uma vez que a acurácia de classificação está intimamente relacionada à resolução espacial final da imagem, corroborando com os resultados obtidos por Lian e Chen (2011), onde os autores utilizaram a classificação OBIA em imagens de satélites, com diferentes resoluções espaciais e chegaram à conclusão a classificação oriunda de imagens com 2,5 m de resolução do SPOT, apresentou melhor acurácia e confiabilidade em relação as classificações feitas com imagens do SPOT (10 m) e ASTER (15 m).

Resultado semelhante foi encontrado por Matese et al. (2015), que comprovaram que o levantamento feito com drone como plataforma de imageamento, obteve resultados com maior acurácia e grau de confiança para áreas com diferentes tipos gradientes de vegetação que se comparado com o de uma aeronave tripulada e do satélite *RapidEye* (sensor REIS), devido ao fato das imagens de menor resolução dessas plataformas apresentaram resultados menos satisfatórios ao representar parte da variabilidade fotossintética ativa das áreas avaliadas.

Nesse contexto, tendo como base os valores obtidos pela exatidão global, índice Kappa, teste estatístico Z e dos erros de omissão e comissão da matriz de confusão, demonstram que os resultados obtidos pela correlação entre as classificações OBIA RGB e OBIA NDVI foram excelentes quando comparados, tendo esta última como referencial para a comparação, devido as características do NDVI, que utiliza a resposta espectral das plantas pela reflexão dos espectros da REM, referentes ao vermelho visível e infravermelho próximo, obtido no período de seca do município de Botucatu-SP, e facilitando a diferenciação espectral das forma de vegetação arbórea e herbácea, bem como de alvos abióticos (leito do rio). Demonstrando assim, a existência de uma correlação direta entre uma classificação que é baseada em um índice de vegetação (NDVI), usada como referência e uma

mais tradicional e que é baseada no espectro visível (RGB), permitindo uma boa empregabilidade tanto da classificação segmentada OBIA quanto de índices radiométricos, bem como das imagens com elevada resolução espacial coletadas por drone, com um grande potencial de utilização para o mapeamento dos padrões de uso e ocupação do solo, para as mais diversas finalidades.

5 CONCLUSÕES

O índice radiométrico NDVI proporcionou uma fácil identificação tanto de alvos bióticos (vegetação), quanto abióticos (corpo d'água), devido ao emprego dos espectros do vermelho visível e do infravermelho próximo no seu cálculo, uma vez que os alvos bióticos refletem esses espectros enquanto que os abióticos absorvem, permitindo um grande contraste entre ambos.

Foram identificadas quatro classes de uso e ocupação do solo referentes a Verdade Terrestre (VT) absoluta da APP hídrica da área de estudo, que são: "leito do rio", "sombras", "vegetação arbórea" e "vegetação herbácea". Com a notória predominância da classe "vegetação arbórea" que está dentro do que preza a legislação florestal, apesar da existência de uso indevido do solo na mesma, representado pela classe "vegetação herbácea".

O ensaio de segmentação que obteve o maior número de objetos gerados e, consequentemente, maior detalhamento e acurácia temática nas classificações OBIA foi o com valor dez (10) de similaridade (escala), valor nove (9) para área (*pixels*), valor 0.75 para cor (tonalidade), valor 0.25 para compacidade (forma).

A identificação do uso e ocupação do solo em APP hídrica pela metodologia da Análise de Imagem Baseada em Objeto (OBIA) em ortomosaico RGB e NDVI, mostrou-se eficiente e confiável na delimitação dos principais alvos bióticos e abióticos encontrados nos mosaicos de imagens, obtendo ambas qualidade de classificação "Muito boa" e uma concordância substantiva com o referencial (VT).

A classificação OBIA NDVI apresentou acurácia temática por exatidão global, índice Kappa e validação pelo teste estatístico Z, superiores a OBIA RGB. Tal fato demonstrou uma grande aptidão e empregabilidade de índices radiométricos para o mapeamento e a identificação de classes de uso e ocupação do solo.

A comparação entre as classificações OBIA RGB e OBIA NDVI obteve acurácia temática por exatidão global, índice Kappa e validação pelo teste estatístico Z com valores considerados muito bons, possuindo qualidade de classificação "Excelente" e concordância quase perfeita com o referencial. Dessa maneira,

demonstrou com confiabilidade a correlação existente entre uma classificação visual (OBIA RGB) e uma baseada em índice de vegetação (OBIA NDVI).

A classe “vegetação arbórea” foi a que obteve os menores erros tanto por omissão, quanto por comissão, garantindo uma grande confiança de classificação para usuário e produtor. Em contrapartida, a classe “sombras”, apresentou os maiores valores referentes a erros de omissão e comissão, por conta da maior confusão de *pixels* gerada por essa classe com *pixels* de outras classes, devido ao fenômeno de ambiguidade espectral por semelhança, proporcionando menor confiança de classificação.

As imagens com elevada resolução espacial coletadas por drone demonstraram flexibilidade de utilização, podendo ser usadas tanto para uma classificação visual como a OBIA RGB, quanto para uma classificação baseada em um índice radiométrico como a OBIA NDVI. Dessa forma, possui elevado potencial para o mapeamento de dinâmica da paisagem e do comportamento da vegetação e podem ser utilizadas com grande confiabilidade na análise ambiental.

Os dados obtidos pelo presente estudo, podem contribuir também para melhorar e aperfeiçoar as técnicas empregadas no monitoramento ambiental, contribuindo, dessa maneira, para a fiscalização e o cumprimento da legislação florestal brasileira.

REFERÊNCIAS

ABREU, M. V. S. **Introdução ao Generalitat de Valência/ESP (gvSIG)**. Viçosa, MG: EJEAG-UFV, 2012. 120 p.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. ANAC. **Regulamentação da ANAC sobre drones completa um ano em vigor**. 2018. Disponível em: <http://www.anac.gov.br/noticias/2018/regulamentacao-da-anac-sobre-drones-completa-um-ano-em-vigor>. Acesso em: 10 mar. 2019.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. ANAC. Resolução nº 419, de 2 de maio de 2017. Regulamento brasileiro da aviação civil especial RBAC-E nº 94. Requisitos gerais para aeronaves não tripuladas de uso civil. **Diário Oficial da União**, Brasília, DF, 03 maio 2017. Disponível em: https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94/@@display-file/arquivo_norma/RBACE94EMD00.pdf. Acesso em: 10 mar. 2019.

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. ANAC. Instrução Suplementar - IS Nº 21-002 Revisão A, de 4 de outubro de 2012. Orienta a emissão de Certificado de Autorização de Voo Experimental com base no Regulamento Brasileiro da Aviação Civil nº 21 – RBAC 21 para Veículos Aéreos Não Tripulados – VANT. **Diário Oficial da União**, Brasília, DF, 05 out. 2012. Disponível em: http://www.anac.gov.br/assuntos/legislacao/legislacao-1/iac-e-is/is/is-21-002a/@@display-file/arquivo_norma/IS%2021-002A.pdf. Acesso em: 23 jun. 2018.

AGRESTI, A. **Categorical data analysis**. 2. ed. Hoboken, NJ, EUA: John Wiley & Sons, Inc., 2002. 718 p.

ALBUQUERQUE, E. M. ANDRADE, S. C. P.; MORAIS, H. F.; DINIZ, J. M. T.; SANTOS, C. A. C. Análise do comportamento do NDVI e NDWI sob diferentes intensidades pluviométricas no município de Sousa-PB. **Revista Estudos Geoambientais**, Rio Tinto, v. 1, n. 1, p. 01-11, 2014.

ALENCAR-SILVA, T.; MAILLARD, P. Segmentação de imagens de alta resolução utilizando o programa SMAGIC. In: XIV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2009, Natal. **Anais...** Natal, 2009. p. 6743-6750.

AL-SHARIF, A. A. A.; PRADHAN. B. Monitoring and predicting land use change in Tripoli Metropolitan City using an integrated Markov chain and cellular automata models in GIS. **Arabian Journal of Geosciences**, Springer, v. 7, n. 10, p. 4291-4301. 2014.

ANTONELLI, V. R.; BATISTA, R. C. B. Caracterização da avifauna na Fazenda Experimental Lageado, Botucatu, São Paulo. **Atualidades Ornitológicas**, Ivaiporã, n. 208, p. 42-52, 2019.

ANTONINI, I. G. **Lageado**: um esboço de sua história. Botucatu: Faculdade de Ciências Agrônômicas - Universidade Estadual Paulista “Júlio de Mesquita Filho”, 1998. 11 p.

ANTUNES, A. F. B.; LINGNAU, C.; CENTENO, J. A. S. Object oriented analysis and semantic network for high resolution image classification. **Bulletin of Geodetic Sciences**, Curitiba, v. 9, n. 2, p. 233-242, 2003.

ANTUNES, A. F. B.; STURM, U. Segmentação orientada a objeto aplicado ao monitoramento de ocupações irregulares em áreas de proteção ambiental. In: XII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2005, Goiânia. **Anais...** Goiânia, 2005. p. 2019-2026.

ARAGÃO, L. P.; FOGAÇA, T. R.; CATTANI, P. E.; CANEPARO, S. C. Geoprocessamento aplicado à seleção de áreas para implantação de parques urbanos na bacia do rio Verde/PR. **Geografia (Londrina)**, Londrina, v. 24, n. 1, p. 19-38, 2015.

ARAÚJO, E. P.; TELES, M. G. L.; LAGO, W. J. S. Delimitação das bacias hidrográficas da Ilha do Maranhão a partir de dados SRTM. In: XIV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2009, Natal. **Anais...** Natal, 2009. p. 4631-4638.

BAATZ, M.; SCHÄPE, A. **Mutiresolution Segmentation**: An optimization approach for high quality multiscale image segmentation. München. 2001. Disponível em: <http://www.definiens.com>. Acesso em: 25 jul. 2017.

BARBOSA, A. H. S.; CARVALHO, R. G.; CAMACHO, R. G. V. Aplicação do NDVI para a Análise da Distribuição Espacial da Cobertura Vegetal na Região Serrana de Martins e Portalegre - Estado do Rio Grande do Norte. **Revista do Departamento de Geografia**, São Paulo, v. 33, n. 1, p. 128-143, 2017.

BASTIAANSSEN, W. G. M.; MOLDEN, D. J.; MAKIN, I. W. Remote sensing for irrigated agriculture: examples from research and possible applications. **Agricultural Water Management**, Colombo, v. 46, n. 2, p. 137-155, 2000.

BATISTA, F. F. **Influência de modelos de dependência espacial na definição de mapas temáticos**. 2012. 70 p. Dissertação (Mestrado em Estatística Aplicada e Biometria) - Universidade Federal de Viçosa, Viçosa, 2012.

BATISTELLA, M.; MORAN, E. F. **Geoinformação e monitoramento ambiental na América Latina**. São Paulo, SP: SENAC, 2008. 283 p.

BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS ready information. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 58, n. 3-4, p. 239-258, 2004.

BISHOP, Y.; FIENBERG, S.; HOLLAND, P. **Discrete multivariate analysis: Theory and practice**. Cambridge, MIT. 575 p. 1975.

BLASCHKE, T. Object based image analysis for remote sensing. **Journal of Photogrammetry and Remote Sensing**, v. 65, n. 1, p. 02-16, 2010.

BLYENBURGH, P. V. UAS: The Global Perspective with a Focus on Light UAS. In: Seminário Internacional de VANT, 2010, São José dos Campos. **Palestras...** São José dos Campos, 2010.

BORATTO, I. M. P.; GOMIDE, R. L. Aplicação dos índices de vegetação NDVI, SAVI e IAF na caracterização da cobertura vegetativa da região Norte de Minas Gerais. In: XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2013, Foz do Iguaçu. **Anais...** Foz do Iguaçu, 2013. p. 7345-7352.

BRASIL. Lei nº 12.727, de 17 de outubro de 2012. Altera a Lei nº 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa; altera as Leis nos 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; e revoga as Leis nos 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, a Medida Provisória nº 2.166-67, de 24 de agosto de 2001, o item 22 do inciso II do art. 167 da Lei nº 6.015, de 31 de dezembro de 1973, e o § 2º do art. 4º da Lei nº 12.651, de 25 de maio de 2012. **Diário Oficial da União**, Brasília, DF, 18 out. 2012a. Disponível em: http://www.planalto.gov.br/ccivil_03/_Ato2011-2014/2012/Lei/L12727.htm. Acesso em: 13 jul. 2017.

BRASIL. Lei nº 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa; altera as Leis nos 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis nos 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a Medida Provisória nº 2.166-67, de 24 de agosto de 2001; e dá outras providências. **Diário Oficial da União**, Brasília, DF, 28 mai. 2012b. Disponível em: http://www.planalto.gov.br/ccivil_03/_Ato2011-2014/2012/Lei/L12651.htm. Acesso em: 13 jul. 2017.

CÂMARA, G.; SOUZA, R. C. M.; FREITAS, U. M.; GARRIDO, J. SPRING: Integrating remote sensing and gis by object-oriented data modelling. **Computers & Graphics**, Elsevier, v. 20, n. 3, p. 395-403. 1996.

CAMPOS, R. A.; FONSECA, D. F.; FARIA, S. D.; ELMIRO, M. A. T. Classificação orientada a objeto para mapeamento do uso e cobertura do solo do município de Rio Acima - MG: por crescimento de regiões e por extração de objetos. In: XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2013, Foz do Iguaçu. **Anais...** Foz do Iguaçu, 2013. p. 8035-8042.

CARVALHO, W. A.; ESPÍNDOLA, C. R.; PACCOLA, A. A. Levantamento de solos da Fazenda Lageado Estação Experimental "Presidente Médici". **Boletim Científico da Faculdade de Ciências Agronômicas UNESP**, Botucatu, n. 1, 1983. 95 p.

CASANOVA, M. A.; CÂMARA, G.; DAVIS JÚNIOR, C. A.; VINHAS, L.; QUEIROZ, G. R. **Bancos de dados geográficos**. Curitiba, PR: MundoGEO, 2005. 506 p.

CATELANI, C. S.; BATISTA, G. T.; PEREIRA W. F. Adequação do uso da terra em função da legislação ambiental. In: XI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2003, Belo Horizonte. **Anais...** Belo Horizonte, 2003. p. 559-566.

CENTRO DE INTELIGÊNCIA EM FLORESTAS. CIFlorestas. **Cartilha do código florestal brasileiro**. 2018. Disponível em: http://www.ciflorestas.com.br/cartilha/APP-localizacao-e-limites_protecao-conservacao-dos-recursos-hidricos-dos-ecossistemas-aquaticos.html. Acesso em 20 de ago. 2018.

CHAVEZ, P. S. An Improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, Elsevier, v. 24, n. 3, p. 459-479, 1988.

CHUVIECCO, E. **Fundamentos de Teledetección Espacial**. 2. ed. Madrid, Espanha: Ediciones Rialp, 1995. 449 p.

COHEN, J. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, v. 20, n. 1, p. 37-46. 1960.

COHENCA, D.; CARVALHO, R. Comparação de métodos de classificação OBIA, Máxima Verossimilhança e Distância Mínima em imagem OLI/Landsat-8 em área de alta diversidade de uso do solo. In: XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2015, João Pessoa. **Anais...** João Pessoa, 2015. p. 1035-1042.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: Principles and Practices**. 3. ed. Boca Raton, FL, EUA: CRC Press, 2019. 346 p.

CRIADO, R. C.; PIROLI, E. L. Pagamento por Serviços Ambientais na Gestão dos Recursos Hídricos no Brasil. In: **Revista Geografia em Atos (GeoAtos)**, Presidente Prudente, v. 1, n. 12, p. 54-74, 2012.

CUNHA, P. D.; RITTER, L. G.; BORBA, W. F. Vulnerabilidade ambiental e áreas de infiltração máxima de água. **Revista Monografias Ambientais (REMOA)**, Santa Maria, v. 13, n. 5, p. 3761-3776, 2014.

DEMARCHI, J. C.; PIROLI, E. L.; ZIMBACK, C. R. L. Análise temporal do uso do solo e comparação entre os índices de vegetação NDVI e SAVI no município de Santa Cruz do Rio Pardo - SP usando imagens Landsat-5. **RA'E GA**, Curitiba, v. 21, p. 234-271, 2011.

EASTMAN, J. R. **IDRISI Taiga guide to GIS and image processing**. Worcester, MA, EUA: Clark Labs - Clark University, 2009. 341 p.

ECKHARDT, R. R.; LIMA, D. F. B.; REMPEL, C.; DIEDRICH, V. L.; SILVA, J. F. Utilização do SIG SPRING na organização de bancos de dados geográficos municipais - o caso do município de Vespasiano Corrêa - RS - Brasil. In: XIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2007, Florianópolis. **Anais...** Florianópolis, 2007. p. 3853-3860.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. EMBRAPA. **Sistema brasileiro de classificação de solos**. 5. ed. Brasília, DF: EMBRAPA, 2018. 356 p.

FALKNER, E.; MORGAN, D. **Aerial mapping methods and applications**. 2 ed. Boca Raton, FL, EUA: Lewis Publishers, 2001. 218 p.

FERREIRA, E.; DANTAS, A. A. A.; MORAIS, A. R. Exatidão na classificação de fragmentos de matas em imagem do satélite Cbers-CCD, no município de Lavras, MG. In: XIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2007, Florianópolis. **Anais...** Florianópolis, 2007, p. 887-894.

FERREIRA, M. C. Considerações teórica-metodológicas sobre as origens e a inserção do Sistema de Informação Geográfica na Geografia. In: VITTE, A. C. (org.) **Contribuições à história e à epistemologia da geografia**. Rio de Janeiro, RJ: Bertrand Brasil, 2007. 294 p.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. In: XIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2007, Florianópolis. **Anais...** Florianópolis, 2007. p. 5755-5762.

FITZ, P. R. **Geoprocessamento sem complicação**. São Paulo, SP: Oficina de Textos, 2008. 160 p.

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. 3. ed. São Paulo, SP: Oficina de Textos, 2011. 128 p.

FLORENZANO, T. G. **Geomorfologia: conceitos e tecnologias atuais**. São Paulo, SP: Oficina de Textos, 2008. 320 p.

FRANÇA, L. M. A.; OLIVEIRA, T. H.; PEREIRA, J. A. S.; LINS, T. M. P.; GALVÍNIO, J. D. Spatial analysis of caatinga vegetation in the municipality of Ibimirim-PE. **Journal of Hyperspectral Remote Sensing**, Recife, v. 3, n. 3, p. 59-70, 2013.

FRANCISCO, C. N.; ALMEIDA, C. M. Avaliação de desempenho de atributos estatísticos e texturais em uma classificação de cobertura da terra baseada em objeto. **Boletim de Ciências Geodésicas**, Curitiba, v. 18, n. 2, p. 302-326, 2012.

FREITAS FILHO, M. R. **Análise geoambiental com aplicação de geotecnologias nas nascentes do riacho dos Macacos: bacia do rio Acarajú-CE**. 2004. 91 f. Dissertação (Mestrado em Geografia), Universidade Estadual do Ceará, Fortaleza, 2004.

FURIAN, P. H. 2014. **Espectro Eletromagnético**. Disponível em: <http://www.infoescola.com/fisica/espectro-eletromagnetico/>. Acesso em: 18 ago. 2018.

FURTADO, L. F. A.; FRANCISCO, C. N.; ALMEIDA, C. M. Análise de imagem baseada em objeto para classificação das fisionomias da vegetação em imagens de alta resolução espacial. **Geociências**, São Paulo, v. 32, n. 3, p. 441-451, 2013.

GABRIEL, C. G. F. **Análise comparada de segmentação e classificação orientada por objectos de uma imagem worldview-2**. 2013. 162 p. Dissertação (Mestrado em Gestão do Território, Especialização em Detecção Remota e Sistemas de Informação Geográfica) - Faculdade de Ciências Sociais e Humanas, Universidade Nova de Lisboa, Lisboa, 2013.

GAO, B. C. NDWI - A Normalized Difference Water Index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, Elsevier, v. 58, n. 3, p. 257-266, 1996.

GARCIA, Y. M. **Diagnóstico ambiental da bacia hidrográfica do Ribeirão Pederneiras - Pederneiras/SP**. 2017. 213 p. Tese (Doutorado em Agronomia) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2017.

GARCIA, Y. M. **Conflitos de uso do solo em APPs na bacia hidrográfica do Córrego Barra Seca (Pederneiras/SP) em função da legislação ambiental**. 2014. 126 f. Dissertação (Mestrado em Agronomia) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2014.

GARCIA, Y. M. **Aplicação do Código Florestal como subsídio para o planejamento ambiental na bacia hidrográfica do Córrego do Palmitalzinho - Regente Feijó - São Paulo**. Trabalho de Conclusão (Bacharelado - Geografia) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia - Presidente Prudente: [s.n], 2011, 145 f.

GOMES, M. D. A. **Coeficiente de cultivo para a videira com base no Índice de Vegetação por Diferença Normalizada obtido com uso de VANT**. 2019. 100 p. Tese (Doutorado em Agronomia) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2019.

GONÇALVES, A. K. **Análise ambiental e morfométrica da bacia hidrográfica do Córrego Santo Antônio - São Francisco Xavier (SP)**. 2016. 81 f. Dissertação (Mestrado em Agronomia) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2016.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. 3. ed. São Paulo, SP: Blucher, 2011. 640 p.

HAWKINS, S. Using a drone and photogrammetry software to create orthomosaic images and 3D models of aircraft accident sites. In: Seminar of International Society of Air Safety Investigators - ISASI, 2016, Reykjavik: Islândia. **Anais...** Reykjavik, 2016. p. 01-26.

HONKAVAARA, E.; SAARI, H.; PÖLÖNEN, I.; HAKALA, T.; LITKEY, P.; MÄKYNEN, J.; PESONEN, L. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. **Remote Sensing**, MDPI, v. 5, n. 10, p. 5006-5039, 2013.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. IBGE. **Manual Técnico de Uso da Terra**. 3. ed. Rio de Janeiro, 2013. 170 p.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. INPE. **SPRING - Sistema de Processamento de Informações Georreferenciadas**. 1991. Disponível em: <http://www.dpi.inpe.br/spring/portugues/index.html>. Acesso em: 10 jun. 2020.

INSTITUTO DE PESQUISAS TECNOLÓGICAS DO ESTADO DE SÃO PAULO. IPT. 1981. **Mapa Geomorfológico do Estado de São Paulo**. Escala 1:1.000.000. São Paulo. 2v.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente**: uma perspectiva em Recursos Terrestres. Tradução de EPIPHANIO, J. C. N. 2. ed. São José dos Campos, SP: Parênteses, 2009. 598 p.

JENSEN, J. R. **Introductory Digital Image Processing: A Remote Sensing Perspective**. 3. ed. Upper Saddle River, New Jersey, USA: Pearson Prentice Hall, 2015. 544 p.

JIN-KI, P.; JONGHWA, P. Crop classification using imagery of drone. In: International Conference on Environmental Engineering and Remote Sensing - EERS2015, 2015, Phuket, Tailândia. **Anais...** Phuket, Tailândia, 2015. p. 91-94.

KNEIPP, R. B. **O estado da arte na utilização de drones para inspeção naval e offshore**. Projeto de graduação (Bacharelado - Engenharia Naval e Oceânica) - Universidade Federal do Rio de Janeiro, Escola Politécnica - Rio de Janeiro, 2018, 67 f.

LANDIM, P. M. B. **Mapa Geológico do Estado de São Paulo**. Escala 1:250.000, São Paulo: IGCE/UNESP - DAEE, 1984.

LANDIS, R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, JSTOR, v. 33, n. 1, p. 159-174, 1977.

LEITE, A. P. **Discriminação do uso da terra na bacia hidrográfica do rio Araquá utilizando índices radiométricos**. 2019. 91 p. Dissertação (Mestrado em Agronomia) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2019.

LEIVAS, J. F.; ANDRADE, R. G.; VICENTE, L. E.; TORRESAN, F. E.; VICTORIA, D. C.; BOLFE, E. L. Monitoramento da seca de 2011/12 a partir do NDWI e NDVI padronizado do SPOT-Vegetation. In: XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2013, Foz do Iguaçu. **Anais...** Foz do Iguaçu, 2013. p. 364-370.

LEPSCH, I. F. **Formação e conservação do solo**. 2. ed. São Paulo, SP: Oficina de Textos, 2010. 216.

LIAN, L.; CHEN, J. Research on segmentation scale of multi-resources remote sensing data based on object oriented. **Procedia Earth and Planetary Science**, Elsevier, v. 2, n. 1, p. 352-357, 2011.

LIU, W. T. H. **Aplicações de sensoriamento remoto**. 1. ed. Campo Grande, MS: Uniderp, 2007. 881 p.

LORENZZETTI, J. A. **Princípios Físicos de Sensoriamento Remoto**. São Paulo, SP: Blucher, 2015. 293 p.

LOURENÇO, R. W.; LANDIM P. M. B. Estudo da variabilidade do “índice de vegetação por diferença normalizada /NDVI” utilizando krigagem indicativa. **HALO Environment**, v. 4, n.1, p. 38-55, 2004.

LUCHIARI, A. et al. **Primeira Circular do XV Simpósio Brasileiro de Geografia Física Aplicada** - Reflexões sobre o tema “Uso e a ocupação da terra e as mudanças das paisagens”. 2013. Disponível em: http://www.xvsbgfa2013.com.br/arquivo/Circular_XV-SBGFA_18-02.pdf. Acesso em: 10 jul. 2017.

LUZ, N. B.; ANTUNES, A. F. B.; TAVARES JÚNIOR, J. B. Segmentação multirresolução e classificação orientada a objetos aplicados a imagens Spot-5 para o mapeamento do uso da terra. **Floresta**, Curitiba, v. 40, n. 2, p. 429-446, 2010.

MACHADO, P. A. L. Inovações na Legislação Ambiental Brasileira: A Proteção das Florestas. **Veredas do Direito**, Belo Horizonte, v. 10, n. 19, p. 11-21, 2013.

MACHADO, T. S.; CAIONI, C.; FERNANDES, R. S.; NEVES, R. J.; NEVES, S. M. A. S. Análise de NDVI e NDWI em diferentes intensidades pluviométricas para bacia hidrográfica do rio do Cachoeirinha – Mato Grosso, Brasil. In: V Simpósio de Geotecnologias no Pantanal, 2014, Campo Grande. **Anais...** Campo Grande, 2014. p. 690-699.

MASTELLA, A. F. M.; VIEIRA, C. A. O. Acurácia temática para classificação de imagens utilizando abordagens por pixel e por objetos. **Revista Brasileira de Cartografia**, Monte Carmelo, v. 70, n. especial, p. 1618-1643, 2018.

MATESE, A.; TOSCANO, P.; DI GENNARO, S. F.; GENESIO, L.; VACCARI, F. P.; PRIMICERIO, J.; BELL, C.; ZALDEI, A.; BIANCONI, R.; GIOLI, B. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. **Remote Sensing**, MDPI, v. 7, n. 3, p. 2971-2990, 2015.

MELO, E. T.; SALES, M. C. L.; OLIVEIRA, J. G. B. Aplicação do índice de vegetação por diferença normalizada (NDVI) para análise da degradação ambiental da microbacia hidrográfica do Riacho dos Cavalos, Crateús-CE. **RA'E GA**, Curitiba, v. 23, p. 520-533, 2011.

MENESES, P. R.; ALMEIDA, T. M. **Introdução ao processamento de imagens digitais de sensoriamento remoto**. 1. ed. Brasília, DF: Editora UNB, 2012. 276 p.

MIRŠIJOVSKÝ, J.; LANGHAMMER, J. Multitemporal monitoring of the morphodynamics of a mid-mountain stream using UAS photogrammetry. **Remote Sensing**, MDPI, v. 7, n. 7, p. 8586-8609, 2015.

MONTEBELO, L. A.; CASAGRANDE, C. A.; BALLESTER, M. V. R.; VICTORIA, R. L.; CUTOLO, A. P. A. Relação entre uso e cobertura do solo e risco de erosão nas áreas de preservação permanente na bacia do ribeirão dos Marins, Piracicaba-SP. In: XII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2005, Goiânia. **Anais...** Goiânia, 2005.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support Vector Machines in Remote Sensing: A review. ISPRS. **Journal of Photogrammetry and Remote Sensing Society**, v. 66, n. 3, p. 247–259, 2011.

MOURA, A. C. M. **Geoprocessamento na gestão e planejamento urbano**. 3. ed. Rio de Janeiro, RJ: Editora Interciência, 2014, 286 p.

MOUTINHO, O.; RODRIGUES, A.; GONÇALVES, J. A.; SOUSA, J. J.; BENTO, R. Estudo comparativo de software fotogramétrico em diferentes ambientes com RPAS: Comercial vs. Open Source. In: VIII Conferência Nacional de Cartografia e Geodesia - CNCG, 2015, Amadora: Portugal. **Anais...** Amadora, 2015. p. 01-08.

N-BARBOSA, K. M.; ACCO, M.; KIRCHNER, F. F. Classificação de imagens ikonos e comparação por meio de segmentação e fotointerpretação da área amostral. In: XI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2003, Belo Horizonte. **Anais...** Belo Horizonte, 2003. p. 281-283.

NEVES, A. I. P. B. **Classificação da ocupação do solo através da segmentação de uma imagem de satélite de alta resolução**. 2013. 74 p. Projeto de Mestrado em Gestão do Território, Especialização em Detecção Remota e Sistemas de Informação Geográfica - Faculdade de Ciências Sociais e Humanas, Universidade Nova de Lisboa, Lisboa, 2013.

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo, SP: Blucher, 2010. 387 p.

OUYANG, Z.; ZHANG, M.; XIE, X.; SHEN, Q.; GUO, H.; ZHAO, B. A comparison of pixel-based and object-oriented approaches to VHR imagery for mapping saltmarsh plants. **Ecological Informatics**, Elsevier, v. 6, n. 2, p. 136-146, 2011.

PARANHOS FILHO, A. C.; LASTORIA, G.; TORRES, T. G. **Sensoriamento Remoto Ambiental Aplicado: Introdução às Geotecnologias**. Campo Grande, MS: Editora UFMS, 2008. 198 p.

PEGORARO, A.; BONETTI, T. P.; GERMANO, R. M. Arquitetura de banco de dados geográfico. In: XIV Semana de Informática de Paranavaí - SEINPAR, 2014, Paranavaí. **Anais...** Paranavaí, 2014.

PEREIRA, L. S.; SILVA, D. O.; PAMBOUKIAN, S. V. D. Sensoriamento remoto aplicado à agricultura de precisão no cultivo de bambu. **Revista Mackenzie de Engenharia e Computação**, São Paulo, V. 16, n. 1, p. 08-33, 2016.

PINHEIRO, W. R. F. **Avaliação de krigagens através de indicadores locais para a agricultura de precisão**. 2013. 67 f. Dissertação (Mestrado em Estatística Aplicada e Biometria) - Universidade Federal de Viçosa, Viçosa, 2013.

PIROLI, E. L.; CAMPOS, S. Análise do uso da terra por classes de declividade em microbacia hidrográfica usando geoprocessamento. **Applied Research & Agrotechnology**, Guarapuava, v. 3, n. 1, p. 43-53, 2010.

PIX4D. **Pix4Dmapper**: The leading photogrammetry software for professional drone mapping. 2020. Disponível em: <https://www.pix4d.com/product/pix4dmapper-photogrammetry-software>. Acesso em: 11 jun. 2020.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da Vegetação**. 2. ed. São Paulo, SP: Oficina de Textos, 2012. 176 p.

PONZONI, F. J. **Sensoriamento Remoto no estudo da vegetação**: Diagnosticando a Mata Atlântica. INPE - Instituto de Pesquisas Espaciais, São José dos Campos, 2001.

PROPELLER AERO. **What is Ground Sample Distance (GSD) and how does it affect your drone data**. 2018. Disponível em: <https://www.propelleraero.com/blog/ground-sample-distance-gsd-calculate-drone-data/>. Acesso em: 13 abr. 2019.

QUEIROZ, T. B.; SOUSA, R. S.; BALDIN, T.; BATISTA, F. J.; MARCHESAN, J.; PEDRALI, L. D.; PEREIRA, R. S. Avaliação do desempenho da classificação do uso e cobertura da terra a partir de imagens Landsat 8 e Rapideye na região central do Rio Grande do Sul. **Geociências**, Rio Claro, v. 36, n. 3, p. 569-578, 2017.

RAKHA, T.; GORODETSKY, A. Review of Unmanned Aerial System (UAS) applications in the built environment: Towards automated building inspection procedures using drones. **Automation in Construction**, Elsevier, v. 93, p. 252-264, 2018.

REIS, R. S. **O que é o ArcGIS 8.3**. 2016. Disponível em: http://www.ctec.ufal.br/professor/rsr/apostila-arccgis/Capitulo1_OQueEOArcGis.pdf. Acesso em: 10 jul. 2020.

RIBEIRO, C. R. **Planejamento ambiental e gestão de recursos hídricos na bacia hidrográfica da Represa de Chapéu D'Uvas - Zona da Mata e Campo das Vertentes/MG**. 2012. 525 f. Dissertação (Mestrado em Geografia) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista "Júlio de Mesquita Filho", Presidente Prudente, 2012.

RISTOW, S. F. P. Uso de geotecnologias livres para apoio à gestão de bacias hidrográficas: prática com Quantum GIS (QGIS) - Versão 2.2.0. Universidade Federal de Santa Catarina. 2014, 75 p. **Apostila**. Departamento de Engenharia Sanitária e Ambiental. Florianópolis - Santa Catarina, 2014.

RÖHM, S. A.; GIBOTTI, F.; FONSECA FILHO, H.; LOPES, S. C. SPRING como ferramenta de apoio para a formação de especialistas em geoprocessamento. Experiências e resultados do NGeo/UFSCar. In: XXXI Congresso Brasileiro de Educação em Engenharia - COBENGE, 2003, Rio de Janeiro. **Anais...** Rio de Janeiro, 2003. Disponível em: <http://www.abenge.org.br/cobenge/arquivos/16/artigos/IPG833.pdf>. Acesso em: 11 jun. 2020.

RODRIGUES, B. T. **Acurácia de classes altimétricas geradas a partir de produtos de sensores de radar**. 2016. 64 f. Dissertação (Mestrado em Agronomia) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2016.

RODRIGUES, M. T. **Comportamento de Sistemas de Informações Geográficas por meio de classificação supervisionada em diferentes bacias hidrográficas**. 2015. 101 f. Tese (Doutorado em Agronomia) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2015.

RODRIGUES, M. T.; CARDOSO, L. G.; CAMPOS, S.; BARROS, Z. X. RODRIGUES, B. T. Comportamento do software Terraview na classificação supervisionada em diferentes bacias. **Energia na Agricultura**, v. 31, n. 3, p. 282-290, 2016.

RODRIGUES, M. T.; RODRIGUES, B. T. Aplicação do Índice da Vegetação por Diferença Normalizada (NDVI) em imagens CBERS 2B no município de Botucatu-SP. **BIOENG**, Tupã, v. 6, n. 3, p. 139-147, 2012.

RODRIGUES, M. T.; RODRIGUES, B. T.; TAGLIARINI, F. S. N. Comparação do desempenho de Sistemas de Informação Geográfica (IDRISI Selva e ArcGIS®) por meio de processamento digital de imagem. **Fórum Ambiental da Alta Paulista**, Tupã, v. 10, n. 2, p. 265-280, 2014.

ROSA, R. Geomática no Brasil: Histórico e perspectivas futuras. **GeoFocus (Informes y comentarios)**, Bellaterra, n. 9, p. 29-40, 2009.

ROSA, R. **Introdução ao sensoriamento remoto**. 2. ed. Uberlândia, MG: Editora UFU, 1992. 264 p.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A. **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. Texas: College Station, 1974. 371 p.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: Third ERTS Symposium, 1973, Washington-DC, EUA. **Anais...** Washington, DC: NASA, 1973. p. 309-317.

SANTIAGO & CINTRA. **Pix4Dmapper: fotogrametria para mapeamento com drones**. 2019. Disponível em: <https://www.santiagoocintra.com.br/blog/geo-tecnologias/pix4dmapper-fotogrametria-para-mapeamento-com-drones>. Acesso em: 11 jun. 2020.

SANTOS, A. F. **Estudo agroambiental de uma microbacia hidrográfica, visando sua sustentabilidade**. 2009. 93 f. Tese (Doutorado em Agronomia) - Faculdade de Ciências Agrônomicas, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2009.

SANTOS, J. O; SOUZA, M. J. N. Impactos ambientais e riscos de ocupação na bacia hidrográfica do rio Cocó-Ceará. In: SILVA, E. V.; RODRIGUEZ, J. M. M; MEIRELES, A. J. de A. (Orgs). **Planejamento ambiental e bacias hidrográficas**. (Tomo 1) "Planejamento e gestão de bacias hidrográficas". Fortaleza: Edições UFC, 2011, p.87-120.

SARAIVA, D. F. **Classificação orientada a objeto para mapeamento da vegetação sobre canga couraçada**. 2013. 42 f. Curso de Especialização em Geoprocessamento - Instituto de Geociências, Universidade Federal de Minas Gerais, Belo Horizonte, 2013.

SARTORI, A. A. C.; SILVA, R. F. B.; PIANUCCI, M. N.; ZIMBACK, C. R. L. Influência do período de estiagem no Índice de Vegetação (NDVI), no município de Botucatu-SP. In: XIV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2009, Natal. **Anais...** Natal, 2009. p. 4363-4369.

SERRA, P.; PONS, X. Monitoring farmer's decisions on Mediterranean irrigated crops using satellite image time series. **International Journal of Remote Sensing**, Taylor & Francis Online, v. 29, n. 8, p. 2293-2316, 2008.

SCHOWENGERDT, R. A. **Remote Sensing: Models and Methods for Image Processing**. 3. ed. Cambridge, MA, EUA: Academic Press, 2007. 560 p.

SHIMABUKURO, Y. E.; MAEDA, E. E.; FORMAGGIO, A. R. Sensoriamento Remoto e Sistemas de Informações Geográficas aplicados ao estudo dos recursos agrônomicos e florestais. **Ceres**, Viçosa, v. 56, n. 4, p. 399-409, 2015.

SILVA, A. A.; OLIVEIRA, A. P. G.; PARANHOS FILHO, A. C.; GRIGIO, A. M. **Uso do eCognition 8.9 para classificação de imagem de alta resolução**. 1. ed. Mossoró, RN: Editora UERN, 2016. 107 p.

SILVA, E. T. J. B. Veículos aéreos não tripulados: panorama atual e perspectivas para o monitoramento de atividades ilícitas na Amazônia. In: XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2013, Foz do Iguaçu. **Anais...** Foz do Iguaçu, 2013. p. 9324-9331.

SILVA, J. A. A.; NOBRE, A. D.; MANZATTO, C. V.; JOLY, C. A.; RODRIGUES, R. R.; SKORUPA, L. A.; NOBRE, C. A.; AHRENS, S.; MAY, P. H.; SÁ, T. D. A.; CUNHA, M. C.; RECH FILHO, E. L. **O Código Florestal e a Ciência**: contribuições para o diálogo. São Paulo: Sociedade Brasileira para o Progresso para o diálogo. SBPC; Academia Brasileira de Ciências, ABC, 2011, 124 p. Disponível em: <http://www.abc.org.br/IMG/pdf/doc-547.pdf>. Acesso em: jun. 2017.

SILVA, R. S.; PAES, A. T. Teste de concordância Kappa. **Educação Continuada em Saúde Einstein**, São Paulo, v. 10, n. 4, p. 165-166, 2012.

SILVA, V. C. B.; MACHADO, P. S. **Curso de Geografia e Análise Ambiental**. Belo Horizonte: UNIBH, 2010. 62 p.

SILVA JUNIOR, C. A.; FRANK, T.; RODRIGUES, T. C. S. Discriminação de áreas de soja por meio de imagens EVI/MODIS e análise baseada em geo-objeto. **Agriambi**, Campina Grande, v. 18, n. 1, p. 44-53, 2014.

SILVA NETO, M. **A utilização dos Drones na Agricultura**: O guia definitivo. 1. ed. São Paulo, 2015. 27 p. Disponível em: <http://droneng.com.br/>. Acesso em: 16 jul. 2017.

STEHRMAN, S. V.; CZAPLEWSKI, R. L. Design and analysis for thematic map accuracy assessment fundamental principles. **Remote Sensing of Environment**, Elsevier, v. 64, n. 3, p. 331-344, 1998.

STURM, U.; ANTUNES, A. F. B.; LINGNAU, C.; BÄHR, H. P. Análise da ocupação em Áreas de Preservação Permanente (APP) na área urbana do município de Matinhos utilizando a imagem IKONOS II. In: III Colóquio Brasileiro de Ciências Geodésicas - IBGE, 2003, Curitiba. **Anais...** Curitiba, 2003. p. 01-14.

TAGLIARINI, F. S. N. **Técnicas de Geoprocessamento aplicadas na quantificação de perdas de solo em bacia hidrográfica**. 2017. 121 p. Dissertação (Mestrado em Agronomia) - Faculdade de Ciências Agronômicas, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2017.

TAGLIARINI, F. S. N.; RODRIGUES, M. T.; RODRIGUES, B. T.; CAMPOS, S. Índices NDVI e NDWI como ferramentas ao mapeamento do uso e ocupação em bacia hidrográfica. In: XVIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, 2017, Santos. **Anais...** Santos, 2017. p. 2271-2278.

TAMMINGA, A.; HUGENHOLTZ, C.; EATON, B.; LAPOINTE, M. Hyperspatial Remote Sensing of channel reach morphology and hydraulic fish habitat using an unmanned aerial vehicle (UAV): a first assessment in the context of river research and management. **River Research and Applications**, Canada, v. 31, n. 3, p. 379-391, 2015.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, Elsevier, v. 8, n. 2, p. 127-150, 1979.

UNO, Y.; PRASHER, S. O.; LACROIX, R.; GOEL, P. K.; KARIMI, T.; VIAU, A. A.; PATEL, R. M. Artificial neural networks to predict corn yield from compact airborne spectrographic imager data. **Computers and Electronics in Agriculture**. Elsevier, v. 47, n. 2, p. 149-161, 2005.

VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: A comparative study**. 2000. 327 p. Tese (Doutorado em Geografia Física) - University of Nottingham, Nottingham, Inglaterra, 2000.

VIERA, E. G.; ROVANI, F. F. M. O uso da terra em Silveira Martins: uma nova perspectiva por meio das geotecnologias. In: Encontro de Geógrafos de América Latina. Montevideo: Uruguai. 2009. **Anais...** Montevideo, 2009. Disponível em: <http://www.observatoriogeograficoamericalatina.org.mx/egal12/Nuevastecnologias/Cartografiaautomatizada/20.pdf>. Acesso em: 13 mar. 2018.

VIEIRA, M. A. **Análise de imagem orientada a objeto e mineração de dados aplicados ao mapeamento da cultura da cana-de-açúcar**. 2010. 86 f. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2010.

WHITESIDE, T.; AHMAD, W. A comparison of object-oriented and pixel-based classification methods for mapping land cover in northern Australia. In: Conference of the Spatial Sciences Institute - SSC, 2005, Melbourne: Austrália. **Anais...** Melbourne, 2005. p. 1225-1231.

YINGXIN, G. Y.; BROWN, J. F.; VERDIN, J. P.; WARDLOW, B. A five-years analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great plains of the United States. **Geophysical Research Letters**, Malden, v. 34, n. 6, p. 01-06, 2007.

ZAKIA, M. J. B. Atualização Florestal - a Nova Lei Nº 12.651, de 25 de maio de 2012. In: **Curso realizado pelo Instituto de Pesquisas Ecológicas (IPÊ)**. Nazaré Paulista, 2013.

ZAKIA, M. J. B.; PINTO, L. F. G. **Guia para a aplicação da nova lei florestal em propriedades rurais**. Piracicaba, SP: IMAFLORA, 2013. 33 p.

ZANATA, J. M. **Mudanças no uso e cobertura da terra na bacia hidrográfica do Ribeirão Bonito, municípios de Avaré e Itatinga - SP**. 2014. 122 f. Dissertação (Mestrado em Geografia) - Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista "Júlio de Mesquita Filho", Presidente Prudente, 2014.

ZHANG, H.; FRITTS, J. E.; GOLDMAN, S. A. Image segmentation evaluation: A survey of unsupervised methods. **Computer Vision and Image Understanding**, Elsevier, v. 110, n. 2, p. 260-280, 2008.