

**ANÁLISE DA QUALIDADE DA INFORMAÇÃO PRODUZIDA POR
CLASSIFICAÇÃO BASEADA EM ORIENTAÇÃO A OBJETO E SVM
VISANDO A ESTIMATIVA DO VOLUME DO RESERVATÓRIO
JAGUARI-JACAREÍ**

EMERSON LEÃO JUNIOR

PRESIDENTE PRUDENTE

2017

EMERSON LEÃO JUNIOR

**ANÁLISE DA QUALIDADE DA INFORMAÇÃO PRODUZIDA POR
CLASSIFICAÇÃO BASEADA EM ORIENTAÇÃO A OBJETO E SVM
VISANDO A ESTIMATIVA DO VOLUME DO RESERVATÓRIO
JAGUARI-JACAREÍ**

Dissertação de Mestrado submetida ao Programa de Pós-graduação em Ciências Cartográficas da Unesp, Campus de Presidente Prudente, para obtenção do título de Mestre em Ciências Cartográficas.

Área de concentração: Aquisição, Análise e Representação da Informação Espacial

Orientadora: Profa. Dra. Maria de Lourdes Bueno Trindade Galo

Coorientadora: Profa. Dra. Ivana Ivánová

PRESIDENTE PRUDENTE

2017

FICHA CATALOGRÁFICA

Leão, Emerson Junior.
476a Análise da qualidade da informação produzida por classificação baseada em orientação a objeto e SVM visando a estimativa do volume do reservatório Jaguari-Jacareí / Emerson Leão Junior. - Presidente Prudente : [s.n], 2017
xvi, 91 f. : il.

Orientador: Maria de Lourdes Bueno Trindade Galo
Dissertação (mestrado) - Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia
Inclui bibliografia

1. Classificação de imagens. 2. Qualidade de dados espaciais. 3. Propagação de erros. I. Galo, Maria de Lourdes Bueno Trindade. II. Universidade Estadual Paulista. Faculdade de Ciências e Tecnologia. III. Título.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Presidente Prudente

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: **Análise da qualidade da informação produzida por classificação baseada em orientação a objeto e SVM visando a estimativa do volume do Reservatório Jaguarí-Jacaré**

AUTOR: EMERSON LEÃO JÚNIOR

ORIENTADORA: MARIA DE LOURDES BUENO TRINDADE GALO

Aprovado como parte das exigências para obtenção do Título de Mestre em CIÊNCIAS CARTOGRÁFICAS, área: AQUISIÇÃO, ANÁLISE E REPRESENTAÇÃO DE INFORMAÇÕES ESPACIAIS pela Comissão Examinadora:

Profa. Dra. MARIA DE LOURDES BUENO TRINDADE GALO
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

Prof. Dr. PAULO DE OLIVEIRA CAMARGO
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

Prof. Dr. CARLOS ANTÔNIO OLIVEIRA VIEIRA
Departamento de Geociências / UNIVERSIDADE FEDERAL DE SANTA CATARINA

Profa. Dra. IVANA IVANOVA
Professor Visitante do Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

VIDEOCONFERÊNCIA

Presidente Prudente, 25 de abril de 2017

A minha amada mãe, Estela

Agradecimentos

Agradeço, primeiramente, à minha amada mãe, Estela, por ter me dado a graça da vida e, também, por não mensurar esforços para que tivesse a melhor criação possível.

Às professoras Dras. Maria de Lourdes Bueno Trindade Galo e Ivana Ivánová por terem me orientado na realização desta dissertação, por terem compartilhado os seus conhecimentos e pela paciência.

Aos professores Drs. Erivaldo Antonio da Silva, Nilton Nobuhiro Imai por todas as contribuições para a realização deste trabalho no exame de qualificação.

Aos professores Carlos Antonio Oliveira Vieira e Paulo de Oliveira Camargo pelas sugestões que tanto contribuíram para a melhoria desta dissertação.

Aos professores do Departamento de Cartografia da FCT/UNESP pelo apoio e pelos ensinamentos passados.

À Companhia de Saneamento Básico do Estado de São Paulo – SABESP, por terem me recebido em suas dependências e pela cessão de dados de levantamento batimétrico do reservatório Jaguari-Jacareí.

Às funcionárias Cida e Zilda por manterem o ambiente sempre agradável das dependências da Pós-Graduação de Ciências Cartográficas e pelos momentos de descontração.

Aos meus companheiros da Pós-Graduação por propiciarem um ambiente harmonioso.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa para a realização do curso de mestrado.

*‘Se quisermos que a glória e o sucesso acompanhem nossas armas,
jamais devemos perder de vista os seguintes fatores:
a doutrina, o tempo, o terreno, o comando e a disciplina’
(Sun Tzu, A Arte da Guerra)*

Resumo

Considerando o cenário durante a crise hídrica de 2014 e a situação crítica dos reservatórios do sistema Cantareira no estado de São Paulo, este estudo realizado no reservatório Jaguari-Jacareí, consistiu na extração de informações a partir de imagens multiespectrais e análise da qualidade da informação relacionada com a acurácia no cálculo do volume de água do reservatório. Inicialmente, a superfície do espelho d'água foi obtida pela classificação da cobertura da terra a partir de imagens multiespectrais RapidEye tomadas antes e durante a crise hídrica (2013 e 2014, respectivamente), utilizando duas abordagens distintas: classificação orientada a objeto (*Object-based Image Analysis - OBIA*) e classificação baseada em pixel (*Support Vector Machine - SVM*). A acurácia do usuário por classe permitiu expressar o erro para detectar a superfície do espelho d'água para cada abordagem de classificação de 2013 e 2014. O segundo componente da estimação do volume foi a representação do relevo submerso, que considerou duas fontes de dados na construção do modelo numérico do terreno (MNT): dados topográficos provenientes de levantamento batimétrico disponibilizado pela Sabesp e o modelo de superfície AW3D30 (*ALOS World 3D 30m mesh*), para complementar a informação não disponível além da cota 830,13 metros. A comparação entre as duas abordagens de classificação dos tipos de cobertura da terra do entorno do reservatório Jaguari-Jacareí mostrou que SVM resultou em indicadores de acurácia ligeiramente superiores à OBIA, para os anos de 2013 e 2014. Em relação à estimação de volume do reservatório, incorporando a informação do nível de água divulgado pela Sabesp, a abordagem SVM apresentou menor discrepância relativa do que OBIA. Apesar disso, a qualidade da informação produzida na estimação de volume, resultante da propagação da variância associada aos dados envolvidos no processo, ambas as abordagens produziram valores similares de incerteza, mas com uma sutil superioridade de OBIA, para alguns dos cenários avaliados. No geral, os métodos de classificação utilizados nesta dissertação produziram informação acurada e adequada para o monitoramento de recursos hídricos e indicou que a abordagem SVM teve um desempenho sutilmente superior na classificação dos tipos de cobertura da terra, na estimação do volume e em alguns dos cenários considerados na propagação da incerteza.

Palavras-chave: classificação de imagens, máquina de vetor de suporte, análise orientada a objeto, qualidade de dados espaciais.

Abstract

This study aims to extract information from multispectral images and to analyse the information quality in the water volume estimation of Jaguari-Jacareí reservoir. The presented study of changes in the volume of the Jaguari-Jacareí reservoir was motivated by the critical situation of the reservoirs from Cantareira System in São Paulo State caused by water crisis in 2014. Reservoir area was extracted from RapidEye multispectral images acquired before and during the water crisis (2013 and 2014, respectively) through land cover classification. Firstly, the image classification was carried out in two distinct approaches: object-based (Object-based Image Analysis - OBIA) and pixel-based (Support Vector Machine - SVM) method. The classifications quality was evaluated through thematic accuracy, in which for every technique the user accuracy allowed to express the error for the class representing the water in 2013 and 2014. Secondly, we estimated the volume of the reservoir's water body, using the numerical terrain model generated from two additional data sources: topographic data from a bathymetric survey, available from Sabesp, and the elevation model AW3D30 (to complement the information in the area where data from Sabesp was not available). When compare the two classification techniques, it was found that in the image classification, SVM performance slightly overcame the OBIA classification technique for 2013 and 2014. In the volume calculation considering the water level estimated from the generated DTM, the result obtained by SVM approach was better in 2013, whereas OBIA approach was more accurate in 2014. Considering the quality of the information produced in the volume estimation, both approaches presented similar values of uncertainty, with the OBIA method slightly less uncertain than SVM. In conclusion, the classification methods used in this dissertation produced accurate information to monitor water resource, but SVM had a subtly superior performance in the classification of land cover types, volume estimation and some of the scenarios considered in the propagation of uncertainty.

Keywords: image classification, support vector machine, object-based image analysis, spatial data quality

LISTA DE FIGURAS

Figura 1 – Representação do processo de classificação de imagens	6
Figura 2 - Representação dos hiperplanos que separam os dados em duas classes, a separação entre classes é dada pela linha contínua enquanto que as margens são mostradas pelas linhas tracejadas. O hiperplano otimizado (vermelho) é o que apresenta as margens mais largas.....	7
Figura 3 – Exemplos de dados que não são separáveis linearmente. a) SVM linear utilizando-se do artifício de variáveis de folga, b) SVM não linear, separação é dada por uma função de kernel	8
Figura 4 – As margens H_1 e H_2 do SVM são canônicas, ou seja, apresentam distância igual a 1 do hiperplano otimizado.....	10
Figura 5 – SVM com margens suavizadas	14
Figura 6 – Exemplo de mapeamento de dados bidimensionais a um espaço tridimensional por meio de funções de kernel. Em (a), mostra-se os dados em sua forma de entrada, em 2 dimensões; em (b), a separação dos dados em sua dimensão de entrada não se dá de modo linear, mas sim por uma circunferência; e em (c), os dados são projetados a terceira dimensão, e são discriminados por meio de um plano.	17
Figura 7 – Segmentos de imagem com alto grau de homogeneidade espectral	23
Figura 8 - Exemplos de como são estabelecidos os valores de perímetro l (em azul) e bounding box b (em verde) dos objetos de imagem	23
Figura 9 – Exemplo de uma rede hierárquica de classes de cobertura da terra.....	25
Figura 10 – Representação do sistema de coordenadas linha (l) e coluna (p) de uma imagem.....	29
Figura 11 – Efeitos na aquisição de imagem ocasionados pela orientação exterior da plataforma de aquisição. a) translação nas coordenadas X e Y, b) rotação sobre o eixo ω , c) rotação sobre o eixo φ , d) rotação sobre o eixo κ	30
Figura 12 - Delimitação da área de estudo em imagem Landsat-8 adquirida no dia 02 de junho de 2014 (composição colorida com as bandas: 2B, 3G, 4R), bem como sua localização no estado de São Paulo	35
Figura 13 - Estrutura de organização do Sistema Cantareira	36
Figura 14 - Vazão do sistema equivalente do Cantareira no ano de 2013.....	37

Figura 15 - Mosaico das quatro imagens RapidEye que compõem a área de estudos, referentes ao ano de 2013.....	38
Figura 16 – Diagrama das etapas da pesquisa	43
Figura 17 - Esquema de hierarquia de classes, em que Ag se refere a Água, VA é Vegetação Arbórea; VR, Vegetação Rasteira; SE, Solo Exposto e Im Impermeável.....	47
Figura 18 - Regras de pertinência de cada classe	47
Figura 19 - Comportamento espectral dos alvos água, vegetação e solo	48
Figura 20 - Resposta espectral de diferentes elementos que compõem a paisagem urbana.....	49
Figura 21 - Representação do relevo submerso do reservatório Jaguari-Jacareí em 2013 (altitude ortométrica do espelho d'água em 833,51 metros).....	54
Figura 22 - Classificações das imagens RapidEye da área de estudos, abrangendo o entorno do reservatório Jaguari-Jacareí. Imagens tomadas em 2013 classificadas pelo método OBIA (a) e SVM (b); imagens de 2014 resultantes da aplicação das abordagens OBIA (c) e SVM (d).	64
Figura 23 - Recorte da cena de 2014 da área de estudos indicando uma local com cobertura de nuvens (a) e o resultado da classificação OBIA (b) e SVM (c).	65
Figura 24 – Mapa de mudanças ocorridas nos tipos de cobertura da terra do entorno do reservatório Jaguari-Jacareí, entre os anos de 2013 e 2014, obtidas pelas classificações: OBIA (a); SVM (b).	67
Figura 25 - Recorte de uma das áreas do reservatório Jaguari-Jacareí onde houveram mudança de água para arbusto. a) Imagem adquirida em 2012; Imagem adquirida em 2015	68
Figura 26 - MDT do reservatório Jaguari-Jacareí, produzido a partir de dados obtidos por batimetria e do modelo AW3D30.....	71
Figura 27 - Representação espacial das incertezas associadas a cada método utilizado para estimar o volume do Jaguari-Jacareí, em 2013	78
Figura 28 - Representação espacial das incertezas associadas a cada método utilizado para estimar o volume do Jaguari-Jacareí, em 2014	79

LISTA DE TABELAS

Tabela 1 - Exemplo da estrutura da matriz de erro, em que M se refere ao número de classes e n indica o número de elementos amostrais. N é o tamanho da amostra.....	31
Tabela 2 - Data de tomada das cenas RapidEye que compõem a área de estudos, para cada ano da análise, número de pontos de controle usados no registro e resíduo da transformação.	44
Tabela 3 – Matriz de erro de q classes.....	51
Tabela 4 - Matriz de erro referente à classificação OBIA aplicada à imagem RapidEye tomada em 2013	58
Tabela 5 - Matriz de erro referente à classificação SVM aplicada a imagem RapidEye tomada em 2013	59
Tabela 6 - Matriz de erro referente à classificação OBIA aplicada a imagem RapidEye tomada em 2014	59
Tabela 7 - Matriz de erro referente à classificação SVM aplicada a imagem RapidEye tomada em 2014	59
Tabela 8 – Acurácia global, acurácia de usuário, acurácia de produtor e Índice de Concordância Kappa para as classificações realizadas a partir da abordagem OBIA	60
Tabela 9 – Acurácia global, acurácia de usuário, acurácia de produtor e Índice de Concordância Kappa para as classificações realizadas a partir da abordagem SVM	61
Tabela 10 – Variância de K calculadas a partir das abordagens de classificação: OBIA e SVM aplicadas às imagens RapidEye tomadas em 2013 (OBIA13; SVM13) e 2014 (OBIA14; SVM14)	62
Tabela 11 – Valores do teste Z para as classificações OBIA e SVM, para os anos de 2013 e 2014.....	62
Tabela 12 – Teste Z para a verificar de similaridade entre pares de classificações	63
Tabela 13 - Número e proporção de pixels atribuídos a cada classe nos anos de 2013 e 2014, a partir do método OBIA.....	66
Tabela 14 – Número e proporção de pixels atribuídos a cada classe nos anos de 2013 e 2014, a partir do método SVM.....	66

Tabela 15 - Número e proporção de pixels presentes no mapa de detecção de mudanças do reservatório.....	68
Tabela 16 – Proporção da área de estudo ocupada pelo Corpo d'Água, estimada a partir de cada abordagem de classificação, nos anos de 2013 e 2014.....	69
Tabela 17 - Desvios-padrão do estimador estratificado, da estimação de área da classe Corpo d'Água (Ag)e do pixel pertencente a Ag (valores relativos a 1σ de confiança).....	70
Tabela 18 – Cota d'água estimada a partir das superfícies aquáticas definidas nas classificações do reservatório e respectivos desvios-padrão. Na última linha estão indicadas as cotas divulgadas pela Sabesp.....	72
Tabela 19 - Volume do reservatório obtido a partir das cotas estimadas e divulgadas pela Sabesp.....	73
Tabela 20 - Discrepâncias entre os volumes estimado e informado pela Sabesp.....	73
Tabela 21 - Diferença relativa entre as abordagens utilizadas para a estimativa de volume do reservatório Jaguari-Jacareí, em porcentagem	74
Tabela 22 – Valores resultantes da propagação de erros para estimação da profundidade do corpo d'água	75
Tabela 23 – Valores resultantes da propagação de erros na estimação de volume a partir da abordagem OBIA e SVM	76
Tabela 24 – Relação entre a incerteza e o volume estimado em porcentagem	76

LISTA DE QUADROS

Quadro 1 – Principais funções de kernel	18
Quadro 2 – Comparação entre os métodos de segmentação de imagem baseados em descontinuidade e similaridade	20
Quadro 3 – Atributos inerentes às características de objeto	26
Quadro 4 - Classes a serem utilizadas na pesquisa, suas definições e recortes de exemplos em composição de cor verdadeira.....	45
Quadro 5 - Interpretação do Índice de Concordância Kappa	62

Lista de Abreviaturas

- ALOS – *Advanced Land Observing Satellite*
- ANA – Agência Nacional de Águas
- AW3D30 – *ALOS World 3D 30m Mesh*
- DGPS – *Differential Global Positioning Satellite*
- FAO – *Food and Agriculture of United Nations*
- IBGE – Instituto Brasileiro de Geografia e Estatística
- ISO – *International Organization for Standardization*
- JAXA – *Japanese Aerospace Exploration Agency*
- KKT – Karush-Kuhn-Tucker
- LiDAR – *Light Detection and Ranging*
- MDE – Modelo Digital de Elevação
- MDS – Modelo Digital de Superfície
- MDT – Modelo Digital de Terreno
- MMA – Ministério do Meio Ambiente
- ND – Número Digital
- NDVI – *Normalized Difference Vegetation Index*
- PIXEL – *Picture Element*
- OBIA – *Object-Based Image Analysis*
- ROI – *Regions of Interest*
- RMSP – Região Metropolitana de São Paulo
- Sabesp – Companhia de Saneamento Básico do Estado de São Paulo
- SAD – *South American Datum*
- SIG – Sistema de Informação Geográfica
- SVM – *Support Vector Machine*
- TIN – *Triangulated Irregular Network*
- USGS – *United States Geological Survey*
- UTM – Universal Transversa de Mercator
- WGS – *World Geodetic System*

Sumário

1	INTRODUÇÃO	1
1.1	OBJETIVOS.....	4
1.2	ORGANIZAÇÃO DA DISSERTAÇÃO	4
2	FUNDAMENTAÇÃO TEÓRICA	5
2.1	CARACTERIZAÇÃO DE DADOS DE SENSORIAMENTO REMOTO	5
2.2	CLASSIFICAÇÃO DE DADOS DE SENSORIAMENTO REMOTO	5
2.3	SUPPORT VECTOR MACHINE	7
2.3.1	SVMs com margens rígidas.....	9
2.3.2	SVMs com margens suaves	13
2.3.3	SVMs não-linear.....	16
2.4	ANÁLISE DE IMAGEM ORIENTADA A OBJETO	18
2.4.1	Segmentação de Imagens.....	20
2.4.1.1	Segmentação Multirresolução	21
2.4.2	Redes Hierárquicas de Classes	25
2.4.3	Classificação Orientada a Objetos.....	26
2.5	QUALIDADE DE DADOS ESPACIAIS	27
2.5.1	Acurácia Posicional de Imagens	28
2.5.2	Acurácia Temática	31
3	MATERIAIS E MÉTODOS.....	35
3.1	ÁREA DE ESTUDO	35
3.2	MATERIAIS.....	37
3.2.1	Imagens RapidEye	38
3.2.2	Modelo do Relevo submerso.....	39
3.2.2.1	Dados de Profundidade Obtidos por Batimetria.....	40
3.2.2.2	Imagens AW3D30	41
3.3	DESENVOLVIMENTO METODOLÓGICO	42
3.3.1	Pré-Processamento das Imagens RapidEye.....	43
3.3.2	Definição das Classes.....	44
3.3.3	Classificação das imagens RapidEye	45

3.3.4	Análise das Transições nas Margens do reservatório Jaguari-Jacareí	49
3.3.5	Estimativa da Acurácia Temática	50
3.3.6	Estimativa da Área de da Classe Corpo d'Água.....	51
3.3.7	Elaboração do Modelo Digital de Terreno	53
3.3.8	Estimativa de Volume do Reservatório	53
3.3.9	Propagação de Incerteza na Estimativa do Volume	55
4	RESULTADOS E DISCUSSÃO.....	58
4.1	ACURÁCIA TEMÁTICA DAS CLASSIFICAÇÕES	58
4.2	IMAGENS CLASSIFICADAS PARA 2013 E 2014 POR SVM E OBIA	63
4.3	TRANSIÇÕES NA COBERTURA DA TERRA NAS MARGENS DO RESERVATÓRIO JAGUARI-JACAREÍ.....	67
4.4	ÁREA DO CORPO D'ÁGUA EM 2013 E 2014	69
4.5	MDT E COTA D'ÁGUA ESTIMADA EM 2013 E 2015.....	70
4.6	VOLUME ESTIMADO DO RESERVATÓRIO EM 2013 E 2014	73
4.7	INCERTEZA NA ESTIMATIVA DE VOLUME.....	75
5	CONCLUSÕES E RECOMENDAÇÕES	81
6	REFERÊNCIAS	83

1 INTRODUÇÃO

Com a popularização dos Sistemas de Informação Geográfica (SIG), a utilização de dados espaciais nos processos de tomadas de decisões tem-se ampliado, principalmente, aqueles voltados ao monitoramento das mais diversas áreas da atividade humana, como na conservação de florestas (DAS *et al.*, 1996; WULDER; HALL; FRANKLIN, 2005; REDDY; JHA; DADWHL, 2013) e expansão urbana (HATHOUT, 2002; BELAL; MOGHAN, 2011; HEGAZY; KALOOB, 2015), entre outras. Contudo, a utilização de dados espaciais não deve ser feita de forma irrestrita, uma vez que a qualidade destes dados deve ser adequada para o fim a que se destinam, garantindo maior segurança e satisfação na tomada de decisões (HUNTER *et al.*, 2009).

De acordo com Van Oort (2005), além do surgimento de SIG, a maior disponibilidade de dados espaciais adquiridos por satélites, também foi determinante para o aumento do interesse na qualidade de dados. Nesse contexto, destacam-se as imagens orbitais de sensoriamento remoto, algumas delas obtidas sem interrupção desde a década de 1970, por meio de sensores embarcados em plataformas orbitais, e que são utilizados para o monitoramento de recursos sobre a superfície terrestre (JENSEN, 2011).

A importância de descrever a qualidade dos dados espaciais está no fornecimento de informações para auxiliar o usuário final a selecionar aqueles que melhor se adequem às suas necessidades (VAN OORT, 2005). De acordo com a ISO 19157/2013, a descrição da qualidade de dados é realizada a partir de seis elementos: completude, consistência lógica, acurácia posicional, acurácia temática, qualidade temporal e usabilidade.

O mapeamento da superfície terrestre é fundamental para o monitoramento dos recursos naturais e a classificação de imagem é a técnica utilizada para a produção de mapas temáticos a partir de dados de sensoriamento remoto. Nesse processo, é atribuído um rótulo a cada *pixel* conforme suas características numéricas (NOVO, 2008). Com o aumento da capacidade de processamento dos computadores, novos métodos de classificação mais robustos foram desenvolvidos. Dentre as novas abordagens, destacam-se o *Support Vector Machine*, SVM, (HAN; CHEN; FENG, 2015; KHATAMI; MOUNTRAKIS; STEHMAN, 2016) e a análise de imagem orientada ao objeto, OBIA, (MYINT *et al.*, 2011; WHITESIDE; BOGGS; MAIER, 2011; DURO; FRANKLIN; DUBÉ, 2012).

Support Vector Machine é um classificador supervisionado não-paramétrico baseado no *pixel* que consiste na definição de um hiperplano otimizado no espaço multiespectral, o

qual apresenta a maior distância entre duas classes (VAPNIK, 1998). No caso de não houver separação linear das classes, há dois artifícios matemáticos para sua discriminação: inserção de parâmetros de folga, que aumentam a flexibilidade de separação, e/ou utilização de funções de *kernel*, que mapeiam os dados para alguma dimensão superior, na qual essas classes possam ser separáveis linearmente (MOUNTRAKIS; IM; OGOLE, 2011).

Na análise de imagem orientada ao objeto, as classes são atribuídas a grupo de *pixels* com base em suas características espectrais, espaciais e contextuais. Os conjuntos de *pixels* são gerados a partir de segmentação da imagem, na qual *pixels* homogêneos e contíguos são agrupados e passam a representar um mesmo objeto. Dessa forma, além da resposta espectral do alvo, outros atributos podem ser utilizados na classificação, como textura, forma e contexto (SCHWIEWE; TUFTE, 2006).

Via de regra, a avaliação da qualidade de uma classificação de imagens é realizada pelo elemento de acurácia temática, na qual é verificada a concordância entre elementos amostrais de classificação e suas respectivas referências de campo (RICHARDS, 2013). A partir da matriz de erro, que relaciona o resultado obtido da classificação com a verdade terrestre, são extraídas informações estatísticas sobre a qualidade da classificação, como a acurácia de produtor, de usuário e global, além do Índice de Concordância *Kappa* (CONGALTON; GREEN, 1999).

Quando se utiliza imagens classificadas em processos de tomada de decisão, além de avaliar a acurácia temática, é imprescindível a análise da qualidade posicional dos dados. Visto que, durante o georreferenciamento da imagem utilizada na classificação, podem ocorrer erros de posicionamento, relacionadas tanto com as características do instrumento imageador (resolução espacial e radiométrica, calibração geométrica, etc.), como operacionais (erro de pontaria e métodos de reamostragem) (CLARKE; CLARK, 1995).

De acordo com Alsdorf, Rodríguez e Lettenmaier (2007), dados adquiridos a partir de satélites podem ser utilizados para o monitoramento de recursos hídricos pois, permitem tanto extrair informações sobre a variação de área como ao longo do tempo. Kalkan *et al.* (2013), avaliaram o potencial dos classificadores SVM e OBIA para a delimitação da superfície de corpos d'água, e mostraram que o resultado obtido pela abordagem SVM se aproximou mais da vetorização manual de imagens. Zhu, Jia e Lv (2014), utilizaram dados provenientes dos satélites ICESat e Landsat-5 para estabelecer relações entre as variações do nível e da área superficial com as variações de volume do lago Qinghai, localizado na China. Os resultados obtidos mostraram que os dados de sensoriamento remoto podem ser utilizados

nessas estimativas que viabilizam o monitoramento de variações no volume de reservatórios. Muala *et al.* (2014), além de utilizar dados de altimetria e imageamento adquiridos por plataformas orbitais para a estimação de volume, também desenvolveram um modelo matemático para inferir o fluxo de água para o lago Nasser e o reservatório Roseires, localizados no Egito e Sudão, respectivamente.

Baseado no exposto, ou seja, na necessidade de dispor de informação atual e confiável no monitoramento de recursos naturais, considerou-se como estudo de caso, a crise hídrica ocorrida em 2014 e 2015, que comprometeu o abastecimento de água em São Paulo. Esse fato histórico teve início em meados do ano de 2012, quando algumas regiões brasileiras, como o semiárido nordestino e o sudeste, passaram a sofrer com baixos índices de precipitação pluviométrica (ANA, 2015a), acarretando em problemas no fornecimento de água, seja para o consumo humano, seja para a produção industrial e agrícola (JACOBI; CIBIM; LEÃO, 2015).

A Região Metropolitana de São Paulo (RMSP) foi um dos locais que mais sentiu os reflexos causados pela falta de chuvas, pois nesse período se desencadeou uma queda drástica no abastecimento dos reservatórios pertencentes ao Sistema Cantareira, o principal provedor de água para a RMSP (ANA, 2015a). O Cantareira é composto por seis reservatórios que são interligados por meio de canais e túneis, sendo o reservatório Jaguari-Jacareí o maior do conjunto (Sabesp, 2013).

A situação em que se encontravam os níveis de água nos reservatórios em 2014 era tão baixa que foi necessário a utilização de duas cotas da reserva técnica para suprir a demanda da população. Com isso, 210,5 bilhões de litros de água foram retirados do reservatório Jaguari-Jacareí, o que contribuiu para que seu espelho d'água atingisse os menores níveis desde o seu início operacional em 1982 (Sabesp, 2015).

Com base no exposto, este estudo parte da hipótese que as imagens de sensoriamento remoto, submetidas a métodos apropriados de classificação, viabilizam a extração de informações com qualidade temática adequada para o monitoramento contínuo de recursos hídricos.

1.1 Objetivos

O objetivo geral desta dissertação é avaliar a qualidade da informação produzida por meio das abordagens de classificação de imagens orbitais baseada no *pixel* (SVM) e baseada em objeto (OBIA) para o monitoramento de recursos hídricos.

Para alcançar o objetivo geral, foram propostos os seguintes objetivos específicos:

- Comparar a acurácia temática de classificações de uso e cobertura da terra, produzidas pelas abordagens SVM e OBIA, aplicadas a imagens orbitais obtidas antes e durante a crise hídrica;
- Analisar as mudanças na cobertura da terra ocorridas no entorno do reservatório Jaguari-Jacareí no período anterior e durante a crise hídrica;
- Estimar o volume do reservatório Jaguari-Jacareí, antes e durante a crise hídrica;
- Avaliar a qualidade da informação obtida; e
- Definir método voltado para a propagação da qualidade da informação de volume estimado.

1.2 Organização da Dissertação

Esta dissertação está estruturada em seis capítulos. Neste Capítulo 1, faz-se a contextualização do problema e definição dos objetivos, geral e específicos. O Capítulo 2 refere-se à fundamentação teórica do estudo, a qual visa servir como embasamento científico para os tópicos abordados. Os Materiais e Métodos utilizados nesta pesquisa estão descritos no Capítulo 3, assim como o caso de estudo, em que se apresenta a localização do reservatório Jaguari-Jacareí e a caracterização da crise hídrica ocorrida em 2014. No Capítulo 4, estão expostos os resultados alcançados neste trabalho, os quais são discutidos com base nos referenciais teóricos do estudo. Por fim, no Capítulo 5, são apresentadas as conclusões e recomendações para futuros trabalhos relacionados com a presente dissertação.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Caracterização de Dados de Sensoriamento Remoto

Os sistemas de aquisição de dados de sensoriamento remoto são constituídos de equipamentos capazes de registrar a radiação eletromagnética emanada pelas feições presentes na superfície terrestre na forma de imagens ou tabelas, conhecidos como sistemas sensores, a partir dos quais pode se identificar objetos do meio ambiente por meio de suas propriedades físicas, químicas, biológicas ou geométricas (NOVO, 2008).

De acordo com Novo (2008), os sistemas sensores são essencialmente descritos por quatro características de resolução: espacial, espectral, temporal e radiométrica. A resolução espacial é definida como o menor elemento de imagem distinguível, conhecido como *pixel* (elemento pictórico), em termos de medidas na superfície física terrestre (RICHARDS, 2013). O atributo espectral dos sensores é dado pela largura das faixas espectrais e a capacidade do sensor de fazer a distinção entre dois comprimentos de onda do espectro eletromagnético (NOVO, 2008). A característica temporal se trata intervalo de tempo decorrido entre a tomada de duas imagens sobre a mesma área (NOVO, 2008).

Por fim, tem-se que a resolução radiométrica é a capacidade que um sensor apresenta para distinguir as variações da energia emitida por objetos na superfície (NOVO, 2008). Computacionalmente, o armazenamento em forma de radiação eletromagnética não é conveniente. Portanto, a radiação captada é convertida para um sinal elétrico e quantizada como um valor inteiro, o Número Digital (ND). O valor discreto de ND que um *pixel* pode ser representado é dependente da resolução radiométrica do sensor, dada pelo número de bits, Q (SCHOWENGERDT, 2011). A quantidade de NDs, N_{ND} , que pode ser atribuído a um é dado pela Equação 1.

$$N_{ND} = 2^Q \quad (1)$$

Sendo que, o intervalo de valores de ND varia entre $[0, 2^Q - 1]$.

2.2 Classificação de Dados de Sensoriamento Remoto

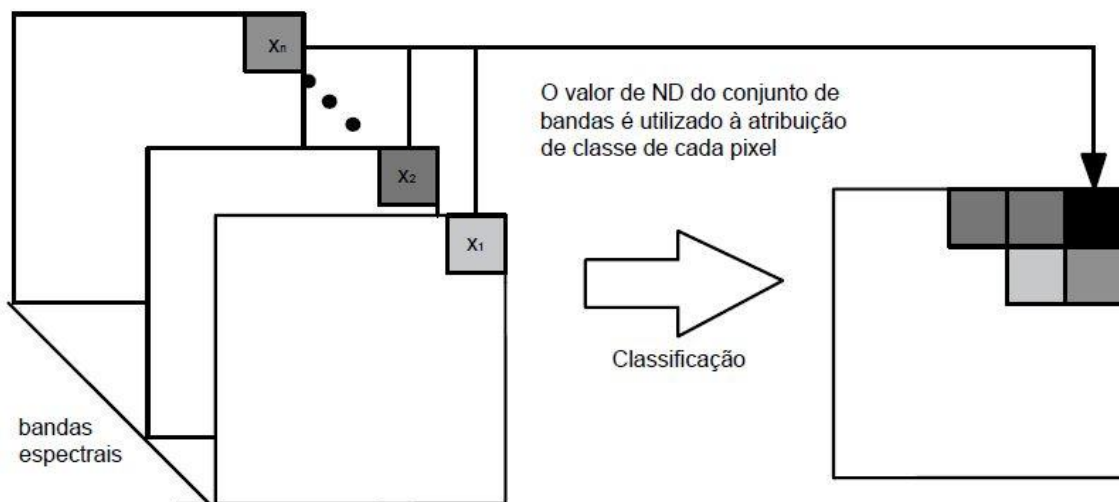
As imagens de sensoriamento remoto podem ser utilizadas para a extração de informações de objetos sobre a superfície. Dentre as várias técnicas existentes voltadas a esse

fim, destaca-se a classificação, a qual consiste em análises quantitativas de suas características numéricas das imagens. Nesse processo, para cada *pixel* da imagem é atribuído um rótulo conforme as suas características espectrais e/ou espaciais (NOVO, 2008).

De acordo com Jensen (2011), os produtos gerados a partir da classificação de imagens são conhecidos como mapeamentos temáticos. A comunicação por meio de mapas é mais efetiva quando se adota um sistema de classificação, pois a partir deste são estabelecidas de forma clara as classes que constarão na informação produzida.

A classificação é realizada por meio de técnicas matemáticas conhecidas como reconhecimento de padrões (NOVO, 2008). Posto que, padrões são tidos como sendo os vetores contendo os valores de NDs registradas em cada banda espectral do *pixel*, $x = [x_1 \ x_2 \ \dots \ x_n]$, como pode ser visto na Figura 1.

Figura 1 – Representação do processo de classificação de imagens



Fonte: Adaptado de RICHARDS (2013)

Segundo Novo (2008), as técnicas de classificação utilizam regras de decisão para atribuição de rótulo ao *pixel*, podendo ser estas determinadas de forma não-supervisionada ou supervisionada. Na primeira abordagem os *pixels* são agrupados conforme a proximidade no espaço multidimensional, definido pelas bandas espectrais da imagem, e associados a classes espectrais, que são previamente desconhecidas pelo analista (RICHARDS, 2013).

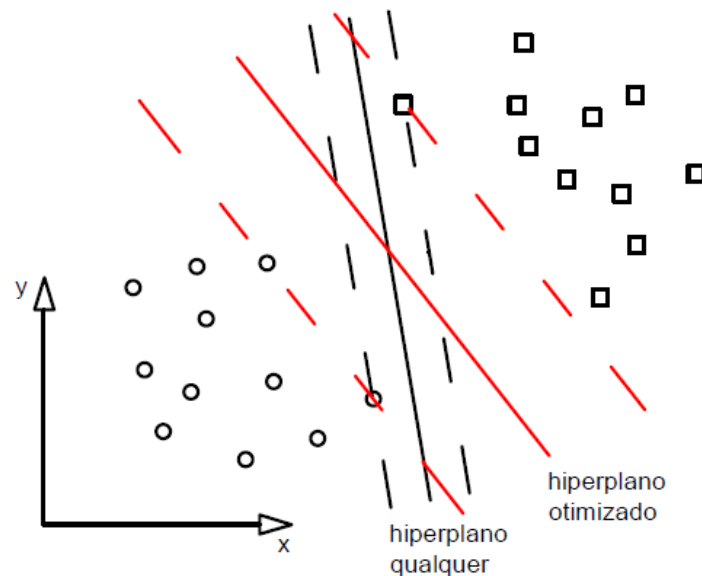
Por outro lado, nas abordagens supervisionadas é necessário que o analista tenha conhecimento prévio da imagem e das classes que constarão no sistema de classificação, pois este deve intervir no processo informando amostras representativas de padrões para cada classe, conhecidas como conjunto de treinamento (RICHARDS, 2013). A partir desse

conjunto, são estimados os parâmetros que constituem as regras de atribuição de rótulos aos *pixels*.

2.3 Support Vector Machine

Support Vector Machine (SVM) é um classificador supervisionado, o qual define um hiperplano na discriminação entre duas classes (VAPNIK, 1998). Embora existam inúmeros hiperplanos que possibilitem a divisão dos dados em duas classes, é desejável estabelecer o qual apresente a maior separação entre as margens das classes, sendo esse delimitador conhecido como hiperplano otimizado, como pode ser visto na Figura 2. Dessa forma, minimiza-se o erro na aplicação de rótulos aos dados.

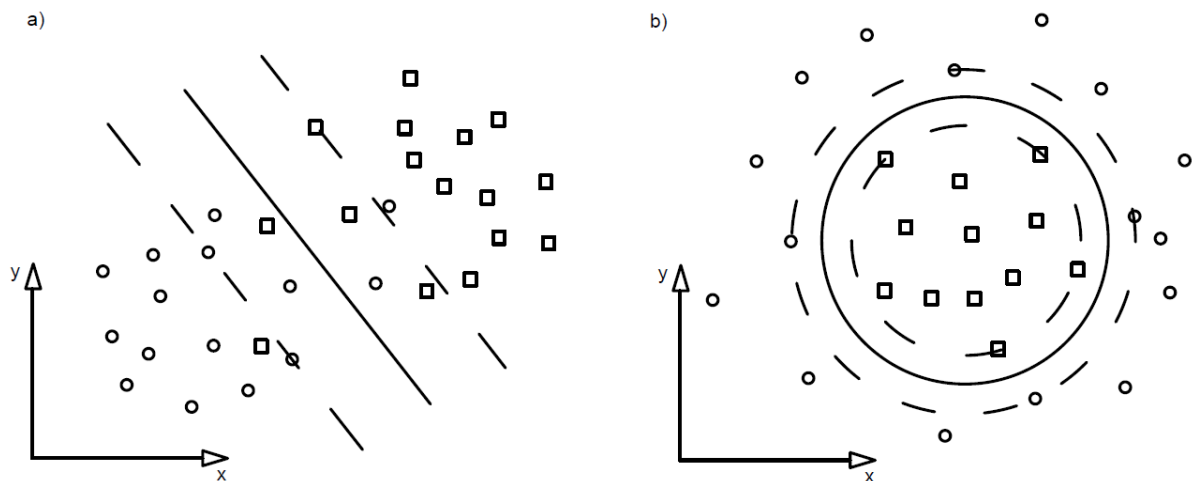
Figura 2 - Representação dos hiperplanos que separam os dados em duas classes, a separação entre classes é dada pela linha contínua enquanto que as margens são mostradas pelas linhas tracejadas. O hiperplano otimizado (vermelho) é o que apresenta as margens mais largas



O SVM é um classificador não paramétrico, ou seja, na regra de decisão para a atribuição de rótulos aos dados não são utilizados quaisquer atributos estatísticos referentes ao conjunto de treinamento, como a média e o desvio padrão dos valores de NDs dos *pixels* que pertencem a uma dada classe de uso e cobertura da terra. Portanto, a quantidade de elementos utilizados no treino não é de suma importância, mas sim que toda a variabilidade inerente a um tipo específico de classe esteja presente no conjunto (FOODY; MATHUR, 2004).

A formulação inicial de SVMs é recomendada a conjuntos de dados que são separáveis de forma linear. Entretanto, há uma quantidade considerável de observações que não são separáveis se modo linear (DAVIES, 2005). Nesses casos, há duas alternativas para o processo de determinação do hiperplano otimizado. A primeira é utilizando variáveis de folga (Figura 3a), recomendável quando a separação entre as classes é quase linear, permitindo assim que uma quantidade mínima de dados possa ocorrer entre as margens de duas classes (RICHARDS, 2013). A alternativa está no emprego de funções de *kernel* (Figura 3b), na qual os dados são mapeados para uma dimensão superior onde possam ser linearmente separáveis (LORENA; CARVALHO, 2007).

Figura 3 – Exemplos de dados que não são separáveis linearmente. a) SVM linear utilizando-se do artifício de variáveis de folga, b) SVM não linear, separação é dada por uma função de *kernel*



Fonte: Adaptado de LORENA; CARVALHO (2007)

Portanto, há três tipos de SVMs: linear com margens rígidas (trata-se de quando os dados são linearmente separáveis), linear com margens suaves (utiliza-se de variáveis de folga para que o conjunto de dados sejam linearmente separáveis, permitindo que haja o mínimo possível de elementos de treinamento entre as margens ou além das margens da outra classe) e não lineares (realiza-se o mapeamento por meio de funções de *kernel*, sobre os dados que originalmente não são separáveis, a uma dimensão superior na qual há uma distinção linear entre as classes).

2.3.1 SVMs com margens rígidas

Considerando x_i , $i = 1, 2, \dots, n$, pertencente a um conjunto de treinamento X e que esses dados são linearmente separáveis entre duas classes, $y = \{-1, +1\}$. A separação pode ser dada por um hiperplano, definido por $w^T x + b = 0$, em que w é um vetor direcional ortogonal ao hiperplano, e b é a distância da origem até o hiperplano (IZENMAN, 2008). Sendo assim, a regra de decisão à atribuição de rótulo aos dados segue conforme ao conjunto de Inequações 2.


$$\begin{cases} y_i = +1, & w^T x_i + b > 0 \\ y_i = -1, & w^T x_i + b < 0 \end{cases} \quad (2)$$

Segundo Theodoridis e Koutroumbas (2003), a utilização de hiperplanos na separação de dados, pode convergir a inúmeras soluções. De acordo com Vapnik (1998), a minimização de erros na atribuição de rótulos ocorre quando se faz uso de um hiperplano otimizado (ou hiperplano de margem máxima), ou seja, os dados de treinamento são separados sem erros e apresentando a distância máxima entre as amostras mais próximas do hiperplano. Esses dados mais próximos definem os limites das classes, hiperplanos equidistantes e paralelos ao otimizado.

Como para dados linearmente separáveis não pode haver erro entre as margens das classes, os parâmetros do vetor w e b são escalonados para que os dados sobre as margens apresentem distância equivalente a $+1$ ou -1 e o hiperplano otimizado seja canônico (Figura 4) (VAPNIK, 2000; LORENA; CARVALHO, 2007). Sendo assim, a regra de decisão para a atribuição é dada pelo conjunto de Inequações 3.

$$\begin{cases} y_i = +1, & w^T x_i + b \geq 1 \\ y_i = -1, & w^T x_i + b \leq -1. \end{cases} \quad (3)$$

Figura 4 – As margens H_1 e H_2 do SVM são canônicas, ou seja, apresentam distância igual a 1 do hiperplano otimizado



Fonte: LORENA; CARVALHO (2007)

Segundo Richards (2013), o conjunto de Inequações 3 pode ser resumido na Inequação 4, a qual é válida para ambas as classes. Nesse caso, se a Inequação 3 é satisfeita, a amostra de treinamento x_i está na classe correta. Vale ressaltar que os pontos sobre as margens retornam valor igual a um.

$$y_i(w^T x_i + b) - 1 \geq 0 \quad (4)$$

considerando que dois elementos, x_1 e x_2 , estão sobre as margens das classes $+1$ e -1 , respectivamente. Além disso, isolando x_i da Inequação 3, tem-se que:

$$x_1 = (1 - b)w^+ \quad (5)$$

$$x_2 = (-1 - b)w^+ \quad (6)$$

em que w^+ é a pseudo inversa do vetor w , dada por $w^T / \|w\|$.

A partir da (Figura 4), é possível notar que ao projetar a diferença $(x_1 - x_2)$ sobre o vetor direcional w , tem-se a largura d de separação das margens. Sendo assim, utiliza-se os termos apresentados nas Equações 5 e 6, para a determinação da distância marginal:

$$d = \frac{(x_1 - x_2) w}{\|w\|}$$

$$d = \frac{(1 - b - (-b - 1))w^+w}{\|w\|}$$

$$d = \frac{2}{\|w\|}. \quad (7)$$

Portanto, para a determinação da maior margem possível basta maximizar d . Entretanto, de acordo com Bazaraa, Sherali e Shetti (2006), a maximização da Equação 7 não é possível computacionalmente, pois não se trata de um problema convexo, não há como maximizar a solução. Com isso, é necessário realizar ajustes na Equação 7, a fim de encontrar a largura máxima de separação entre as margens das classes.

Segundo Forsyth e Ponce (2003), a Equação 8 determina o mesmo mínimo que a Equação 6. Além disso, trata-se de uma função convexa, assim, a sua solução é possível por meios computacionais e é conveniente aos desenvolvimentos matemáticos que serão demonstrados posteriormente.

$$J = \frac{1}{2} \|w\|^2. \quad (8)$$

A definição do problema é dada por:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (9)$$

sujeito a $y_i(w^T x_i + b) - 1 \geq 0, \quad i = 1, 2, \dots, n.$

A minimização da Equação 9 é realizada por meio de otimização com multiplicadores de Lagrange, sendo sujeita as restrições dadas pela Equação 4 e atendendo as condições de Karush-Kuhn-Tucker (KKT) para a solução de problemas convexos (IZENMAN, 2008; THEODORIDIS; KOUTROUMBAS, 2003; VAPNIK, 2000). A função Lagrangiana para a solução do problema é dada pela Equação 10, enquanto que as condições KKT são dadas pelas Equações 11, 12, 13 e 14.

$$\mathcal{L}(w, b, \lambda) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \lambda_i [y_i (w^T x_i + b) - 1] \quad (10)$$

$$\frac{\partial}{\partial w} \mathcal{L}(w, b, \lambda) = 0 \quad (11)$$

$$\frac{\partial}{\partial b} \mathcal{L}(w, b, \lambda) = 0 \quad (12)$$

$$\lambda_i \geq 0, \quad i = 1, 2, \dots, n \quad (13)$$

$$\lambda_i [y_i (w^T x_i + b) - 1] = 0, \quad i = 1, 2, \dots, n. \quad (14)$$

Ao aplicar as derivadas parciais dadas pelas Equações 11 e 12 sobre a função Lagrangiana, Equação 10, obtém-se, respectivamente, as Equações 15 e 16.

$$w = \sum_{i=1}^n \lambda_i y_i x_i \quad (15)$$

$$\sum_{i=1}^n \lambda_i y_i = 0. \quad (16)$$

Sendo assim, aplica-se as Equações 15 e 16 em 10, a fim de eliminar as dependências do vetor direcional w e de b no processo de otimização da largura entre as margens das classes. Com isso, a determinação do hiperplano otimizado passa a depender somente do conjunto de treinamento (LORENA; CARVALHO, 2007). Além disso, o problema apresentado também pode ser resolvido pelo método denominado como ‘dualidade Lagrangiana’, a minimização de uma função Lagrangiana, em w e b , como no caso exposto, é equivalente a solução dada pela maximização dos multiplicadores de Lagrange envolvidos (THEODORIDIS; KOUTROUMBAS, 2003). Portanto, o procedimento de otimização passa a ter a seguinte configuração:

$$\max_{\lambda} \left(\sum_{i=1}^n \lambda_i - \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j x_i^T x_j \right) \quad (17)$$

sujeito a

$$\sum_{i=1}^n \lambda_i y_i = 0$$

$$\lambda \geq 0.$$

A maximização da Equação 17 deve retornar valores iguais ou maiores que zero para os multiplicadores de Lagrange, sendo que para os $\lambda > 0$, é atribuído o nome de *support vectors*, que são os dados sobre as margens das classes (VAPNIK, 1998). Desse modo, é conveniente criar um subconjunto a partir das amostras de treinamento, do qual constará somente os vetores de suporte, possuindo n_{sv} elementos (VAPNIK, 2000). Portanto, a classificação dos dados de teste é dada pela Equação 18.

$$g(x) = \text{sgn}\left(\sum_{j=1}^{n_{sv}} \lambda_j y_j x_j^T x + b^*\right) \quad (18)$$

em que:

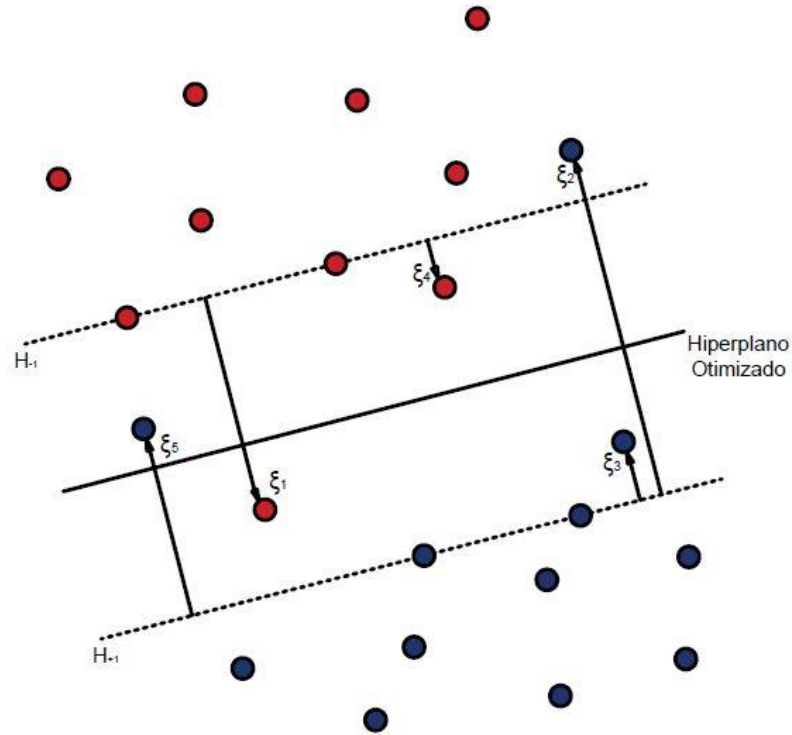
$$b^* = \frac{1}{n_{sv}} \sum_{j=1}^{n_{sv}} \{y_j - \sum_{i=1}^{n_{sv}} \lambda_i y_i x_i^T x_j\}. \quad (19)$$

Sendo que, se $g(x) > 0$, o dado é atribuído a classe $+1$, e em caso contrário é classificado como pertencente a -1 .

2.3.2 SVMs com margens suaves

A separação linear entre classes ocorre raramente, pois a presença de ruídos na obtenção de dados é inevitável (LORENA; CARVALHO, 2007). Devido a isso, é inserido o artifício matemático conhecido como variável de folga “ ζ ”, possibilitando que se tenha separação linear entre as classes. As variáveis de folga suavizam as margens, permitindo assim que haja dados entre as elas (RICHARDS, 2013) (Figura 5).

Figura 5 – SVM com margens suavizadas



Fonte: Adaptado de IZENMAN (2008)

Sendo assim, as amostras de treinamento são pertencentes a uma das três seguintes categorias (IZENMAN, 2008):

1. Dado além da margem ou sobre ela e corretamente classificado, segue a mesma restrição de SVMs com margens rígidas, $y_i(w^T x_i + b) \geq 1$.
2. Dado entre as margens e corretamente classificado, representado na (Figura 5) por ξ_3 e ξ_4 e satisfaz a inequação $0 < y_i(w^T x_i + b) < 1$.
3. Dados classificados incorretamente, representado na (Figura 5) por ξ_1, ξ_2 e ξ_5 , obedecendo a inequação $y_i(w^T x_i + b) < 0$.

Com isso, a Equação 4 pode ser reescrita sob a forma da Equação 20, onde os dados com $\xi = 0$ correspondem ao primeiro caso, $0 < \xi \leq 1$ para o segundo caso, e enquanto que para o cenário que apresenta erros na classificação de dados de treinamento $\xi > 1$.

$$y_i(w^T x_i + b) \geq 1 - \xi \quad (20)$$

Quando se trata de SVMs com margens suaves, além do processo de otimização da largura entre as margens. Há também a necessidade de controlar a quantidade de $\xi > 0$ (THEODORIDIS; KOUTROUMBAS, 2003). Com isso, o problema de otimização pode ser expresso por:

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (21)$$

sujeito a

$$y_i(w^T x + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, n$$

$$\xi_i \geq 0, \quad i = 1, 2, \dots, n.$$

Novamente, há um problema convexo, sendo que, a função Lagrangiana correspondente é dada pela Equação 22.

$$\begin{aligned} \mathcal{L}(w, b, \xi, \lambda, \mu) = & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \mu_i \xi_i - \\ & - \sum_{i=1}^n \lambda_i [y_i(w^T x_i + b) - 1 + \xi_i] \end{aligned} \quad (22)$$

Sendo que μ_i é o multiplicador de Lagrange associado à variável de folga da amostra de treinamento i .

As condições KKT do problema são representadas pelas Equações 23, 24, 25, 26, 27 e 28.

$$\frac{\partial}{\partial w} \mathcal{L}(w, b, \xi, \lambda, \mu) = 0 \text{ ou } w = \sum_{i=1}^n \lambda_i y_i x_i \quad (23)$$

$$\frac{\partial}{\partial b} \mathcal{L}(w, b, \xi, \lambda, \mu) = 0 \text{ ou } \sum_{i=1}^n \lambda_i y_i = 0 \quad (24)$$

$$\frac{\partial}{\partial \xi} \mathcal{L}(w, b, \xi, \lambda, \mu) = 0 \text{ ou } C - \mu_i - \lambda_i = 0, \quad i = 1, 2, \dots, n \quad (25)$$

$$\lambda_i [y_i (w^T x_i + b) - 1 + \xi_i] = 0, \quad i = 1, 2, \dots, n \quad (26)$$

$$\mu_i \xi_i = 0, \quad i = 1, 2, \dots, n \quad (27)$$

$$\mu_i \geq 0, \quad \lambda_i \geq 0, \quad i = 1, 2, \dots, n. \quad (28)$$

A fim de eliminar a dependência do vetor direcional w e de b no processo de determinação da largura máxima entre as classes, igualmente como foi tratado com SVMs com margens rígidas, substituindo as Equações 23, 24 e 25 na função Lagrangiana, Equação 22. Com isso, o problema de otimização é expresso por:

$$\max_{\lambda} \left(\sum_{i=1}^n \lambda_i - \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j x_i^T x_j \right) \quad (29)$$

sujeito a

$$\sum_{i=1}^n \lambda_i y_i = 0$$

$$0 \leq \lambda \leq C, \quad i = 1, 2, \dots, n.$$

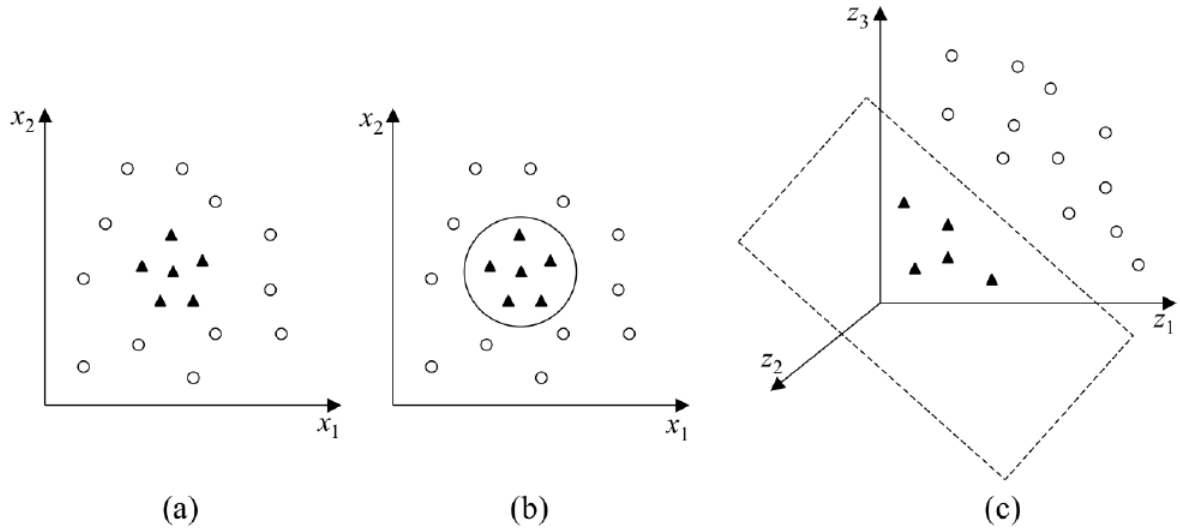
Após a maximização dos multiplicadores de Lagrange a atribuição de classes dá-se de forma semelhante às SVMs de margens rígidas, seguindo a Equação 18.

2.3.3 SVMs não-linear

A suavização de margens para SVMs lineares pode não se adequar ao conjunto de treinamento, pois há dados em que a natureza de separação dos fenômenos em classes não é linear (LORENA; CARVALHO, 2007). Com isso, a generalização da classificação é fraca. De acordo com RICHARD (2013), devido à atribuição de classes por meio de SVMs ser dependente do produto interno entre vetores (como pode ser visto na Equação 18), pode-se utilizar o artifício denominado como funções de *kernel*, ($K(x_i, x_j)$).

Uma função de *kernel* possibilita o mapeamento dos dados de entrada a uma dimensão superior, na qual os dados podem ser separáveis linearmente (IZENMAN, 2008), Figura 6. A vantagem de utilizar esse método está na não necessidade de conhecimento prévio das funções que mapeiam os dados a uma dimensão na qual as classes podem ser separadas por um hiperplano pois, de acordo com o teorema de Mercer, o produto interno de vetores no novo espaço é representado por uma função aplicada ao produto interno do conjunto de dados (THEODORIDIS; KOUTROUMBAS, 2003).

Figura 6 – Exemplo de mapeamento de dados bidimensionais a um espaço tridimensional por meio de funções de *kernel*. Em (a), mostra-se os dados em sua forma de entrada, em 2 dimensões; em (b), a separação dos dados em sua dimensão de entrada não se dá de modo linear, mas sim por uma circunferência; e em (c), os dados são projetados a terceira dimensão, e são discriminados por meio de um plano.



Fonte: LORENA; CARVALHO (2007)

A definição do hiperplano otimizado para casos não lineares dá-se de forma similar às SVMs com margens suaves, onde a única diferença está na aplicação de *kernel* no produto interno apresentado na Equação 30.

$$\max_{\lambda} \left(\sum_{i=1}^n \lambda_i - \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j K(x_i, x_j) \right) \quad (30)$$

sujeito a

$$\sum_{i=1}^n \lambda_i y_i = 0$$

$$0 \leq \lambda \leq C, \quad i = 1, 2, \dots, n.$$

O processo de atribuição de classe aos dados de teste também ocorre de forma similar aos casos lineares, dado pelas equações 18 e 19. Após a maximização da Equação 29, a classificação dos dados é realizada conforme as Equações 31 e 32.

$$g(x) = \text{sgn} \left(\sum_{j=1}^{n_{sv}} \lambda_j y_j K(x_i, x_j) + b^* \right) \quad (31)$$

em que:

$$b^* = \frac{1}{n_{sv}} \sum_{j=1}^{n_{sv}} \{ y_j - \sum_{i=1}^{n_{sv}} \lambda_i y_i K(x_i, x_j) \}. \quad (32)$$

Segundo Vapnik (2000), as principais funções de *kernel* utilizadas para o reconhecimento de padrões são as apresentadas no Quadro 1.

Quadro 1 – Principais funções de *kernel*

Kernel	$K(x_i, x_j)$
Polinomial	$[(x_i^T x_j) + 1]^d$
Função de base radial	$\exp\{-\gamma \ x_i - x_j\ ^2\}$
Sigmoidal	$\tanh(\delta (x_i^T x_j) + c)$

Fonte: Adaptado de THEODORIDIS; KOUTROUMBAS (2003)

Nas funções do Quadro 1, d é o grau do polinômio, γ é o parâmetro de largura da função *kernel*, ao utilizar a função sigmoidal não são todos os valores de parâmetros δ e c que atende as condições do teorema de Mercer, uma possibilidade é $\delta = 2$ e $c = 1$ (THEODORIDIS; KOUTROUMBAS, 2003). Segundo RICHARDS (2013), os parâmetros inerentes aos *kernels* devem ser definidos *a priori*, e seus valores ideais variam conforme o conjunto de dados. Sendo assim, a definição da função e de seus parâmetros é feita por tentativa e erro.

2.4 Análise de Imagem Orientada a Objeto

De acordo com Blaschke (2010), com o lançamento de sistemas orbitais para a aquisição de imagens multiespectrais em alta resolução espacial e radiométrica possibilitou a exploração de novas aplicações, por exemplo, o mapeamento em áreas urbanas (CHEN *et al.*, 2007; GRIPPA *et al.*, 2017).

Contudo, devido ao melhor detalhamento das feições que compõem a paisagem em imagens de alta resolução espacial, os métodos tradicionais de classificação baseada nos atributos espectrais do *pixel*, não conseguiam absorver adequadamente a grande variabilidade presente em uma única classe. Tal fato produz o efeito de ‘sal e pimenta’, o dificulta a identificação da feição/classe na imagem classificada (BLASCHKE; GLÄSSER; LANG, 2007). Devido a maior disponibilidade de imagens com alta resolução espacial e a inadequação de métodos convencionais de classificação desses dados, as abordagens baseadas

em conjuntos de pixels agregados com base nas suas características espectrais e espaciais passaram a ter representatividade tanto no meio científico como comercial, sendo denominada como análise de imagem orientada ao objeto (OBIA, do inglês *Object-based image analysis*) (BLASCHKE, 2010, BLASCHKE et al., 2014). Os diferenciais oferecidos por essa alternativa é a utilização de segmentação de imagem para a geração de objetos e o uso de regras de pertinência para a classificação dos agrupamentos de *pixels*, além de possibilitar a integração com dados provenientes de SIG (Sistema de Informação Geográfica) e LiDAR (*Light Detection And Ranging*) (SCHIEWE; TUFTE, 2007).

Segundo Pinho (2005), OBIA é um método de interpretação de imagens baseado em conhecimento, uma vez que, com a possibilidade de inserir dados de diferentes fontes ao procedimento, o analista pode criar regras de pertinência para a identificação dos objetos a partir de conhecimento prévio sobre a existência do fenômeno no mundo real. Com isso, a classificação aproxima-se do processo de interpretação de imagens, visto que é possível utilizar métricas (além do comportamento espectral associado à cor do objeto) para quantificar outros elementos de interpretação, como textura, forma, padrão e contexto (LANG, 2008). Sendo assim, é imprescindível que o analista possua conhecimento sobre as relações espectrais e espaciais existentes as classes para a discriminação dos objetos. Nesse sentido, enquanto os classificadores convencionais procuram distinguir grupos de pixels com características semelhantes, nas abordagens baseadas em objeto, procura-se definir classes que têm uma existência concreta no mundo real e que expressam características de cor, forma, textura, padrão e contexto na imagem analisada.

Outro conceito relacionado com OBIA é quanto a hierarquia de objetos, pois em uma imagem de sensoriamento remoto, a paisagem é representada como um meio complexo onde há existência de fenômenos que ocorrem em diferentes escalas. A escala tratada em hierarquia de imagem não tem relação com o tamanho dos objetos em si, mas está relacionada com a complexidade em modelar e decompor os objetos da imagem e integração do conhecimento do analista (LANG, 2008).

O grande impulso na utilização de OBIA deve-se ao lançamento do *software* comercial *Definiens eCognition* ocorrido no ano de 2000 (BLASCHKE, 2010). Porém, o uso de sistemas de interpretação de imagens provenientes de sensoriamento remoto com abordagem baseada em conhecimento já estava em desenvolvimento, visto as aplicações: SPAM (McKEOWN; WILSON; McDERMOTT, 1985), SIGMA (MATSUYAMA; HWANG, 1990), MESSIE (CLEMENT et al., 1993) e AIDA (LIEDTKE, 1997).

2.4.1 Segmentação de Imagens

De acordo com Gonzalez e Woods (2008), a segmentação é o processo de particionamento da imagem em regiões ou objetos de *pixels* contíguos. Quando se visualiza uma imagem, intuitivamente, o sistema visual humano se encarrega de segmentá-la, de modo que a imagem, ao invés de ser compreendida como uma entidade complexa, é vista como uma coleção de objetos (CASTLEMAN, 1996). Em processamento digital de imagens, a segmentação de imagens não é um procedimento trivial, o que pode demandar demasiado esforço para a partição da imagem em conjunto de *pixels* (CASTLEMAN, 1996).

Conforme González e Woods (2008) existem duas abordagens para a realização da segmentação de imagens: descontinuidade ou similaridade. Quando é utilizado o critério da descontinuidade, a partição da imagem dá-se pela detecção de bordas. Já a segmentação por similaridade baseia-se em limiarização ou crescimento de regiões. Kaganami e Beiji (2009) descrevem as diferenças no resultado de cada método de segmentação de imagem (Quadro 2). Pelo Quadro 2 e levando em consideração as leis da Gestalt para percepção de objetos, a segmentação baseada em similaridade é a mais recomendada para a análise de imagens orientada ao objeto, uma vez que as regiões de *pixels* gerados apresentam forma fechada. Além disso, a informação multiespectral favorece tal abordagem.

Quadro 2 – Comparação entre os métodos de segmentação de imagem baseados em descontinuidade e similaridade

Baseada em descontinuidade	Baseada em similaridade
Particionamento forma segmentos não necessariamente fechados	Particionamento forma segmentos fechados
Melhoria pouco significativa ao utilizar imagens em várias bandas espectrais	Melhoria significativa ao utilizar imagens multiespectrais

Fonte: Adaptado de KAGANAMI; BEIJI (2009)

A utilização da segmentação para a classificação de imagens possui suas vantagens e limitações. As vantagens do uso de objetos de imagem estão relacionadas a dois aspectos essenciais: na divisão da imagem em agrupamentos de *pixels* contíguos e radiometricamente homogêneos, o que reduz o efeito de ‘sal e pimenta’, característico de classificações baseadas no *pixel* (BLASCHKE, 2010), e devido ao particionamento da imagem em polígonos fechados que possibilita a utilização de outros parâmetros, como forma, textura e contexto, para a discriminação de elementos presentes na cena (LIU; XIA, 2010).

Quanto às limitações de se utilizar objetos de imagem podem ser colocados dois aspectos: subsegmentação, decorrente do uso de um limiar alto, gerando objetos que incorporam muitas variações radiométricas, e supersegmentação, quando o limiar é baixo, acarretando a formação de muitos objetos pequenos (KAMPOURAKI, WOOD; BREWER, 2008). No caso de subsegmentação, os superobjetos gerados podem conter *pixels* pertencentes a mais de uma classe, incorrendo em erro na classificação (LIU; XIA, 2010). Além disso, a utilização de segmentação não adequada, a delimitação dos objetos presentes na cena pode afetar a utilização de parâmetros de forma e área para representá-los, visto que não apresentaram as características que conhecemos dos objetos do mundo real (SONG, CIVCO; HURD, 2005).

2.4.1.1 Segmentação Multirresolução

Na sua abordagem mais simples, a segmentação de imagens por similaridade os *pixels* são considerados inicialmente como entidades independentes e, de acordo com um limiar imposto pelo analista, ocorre junção destes *pixels* em regiões. O processo, denominado crescimento de regiões, ocorre de forma iterativa até que uma condição de agregação não seja mais atendida (GONZALEZ; WOODS, 2008). Devido ao grau de heterogeneidade de um mesmo tipo de cobertura da terra em uma imagem de alta resolução espacial, a aplicação de somente um limiar global de variância espectral no processo de segmentação, pode não ser satisfatória para a discriminação dos elementos que compõem a cena (ANTUNES, 2003; LAMONACA, CORONA; BARBATI, 2008), havendo necessidade de uma abordagem de segmentação que, além do valor inerente à intensidade de brilho do *pixel*, utilize característica de forma dos objetos gerados (BAATZ; SCHÄPE, 2000).

Baatz e Schäpe (2000) desenvolveram um algoritmo denominado segmentação multirresolução, o qual particiona a imagem de forma similar ao método de crescimento de regiões. Entretanto, nessa abordagem os objetos são agrupados aos pares durante cada iteração e utiliza-se um limiar de junção das regiões que permite o uso de características tanto de cor como de forma dos objetos formados, conhecido como parâmetro de escala, e (BURNETT; BLASCHKE, 2003; HAY et al., 2003; BO; HAN, 2010).

A cada iteração é calculado um fator de fusão f , dado pela Equação 33, o qual representa o aumento de heterogeneidade na união de dois segmentos e é dependente tanto da heterogeneidade espectral, h_{cor} , como de forma, h_{forma} , dos objetos (FEITOSA et al., 2007).

A variável f é calculada para toda a adjacência do objeto selecionado, sendo que a junção ocorre quando houver menor heterogeneidade (VAN COILLIE, VERBEKE; DE WULF, 2008) e as regiões somente são unidas se o valor de f for menor que o quadrado do parâmetro e (FEITOSA et al., 2007).

$$f = w_{cor} \cdot h_{cor} + (1 - w_{cor}) \cdot h_{forma} \quad (33)$$

sendo:

w_{cor} - representa o peso dado à componente cor na segmentação.

A heterogeneidade de cor é expressa por:

$$h_{cor} = \sum_c w_c (n_{obj3} \cdot \sigma_c^{obj3} - (n_{obj1} \cdot \sigma_c^{obj1} + n_{obj2} \cdot \sigma_c^{obj2})) \quad (34)$$

em que:

c – identificação da banda espectral

$obj1$ – objeto 1

$obj2$ – objeto 2

$obj3$ – objeto formado da união entre objeto 1 e 2

w_c – peso atribuído a uma dada banda espectral c , $0 \leq w_c \leq 1$

n_i – quantidade de *pixels* do objeto, $i = 1, 2, 3$

σ_c^{obji} – desvio padrão dos valores de *pixels* do objeto i na banda c , $i = 1, 2, 3$.

Pela Equação 34, nota-se que o desvio padrão espectral dos *pixels* dos objetos de imagem possuem papel fundamental no processo de união de segmentos. De acordo com Baatz e Schäpe (2000), a adoção desse critério acarreta na formação de objetos altamente homogêneos (Figura 7), aumento da consistência de contraste dos objetos e o resultado da segmentação reproduz somente diferenças de pequeno grau das margens entre objetos de baixo contraste.

Figura 7 – Segmentos de imagem com alto grau de homogeneidade espectral



Fonte: BAATZ; SCHÄPE (2000)

Segundo Baatz e Schäpe (2000) e Pinho (2005), a heterogeneidade de forma é dependente da heterogeneidade de duas características inerentes aos objetos formados na segmentação: compacidade e suavidade. Compacidade, cp , é a razão entre o perímetro, l , do objeto pela raiz quadrada do número de *pixels* (n) nele contidos. Suavidade, sv , é dada pela razão entre o perímetro do objeto pelo seu *bounding box*, b , (Figura 8), que define o perímetro do quadrilátero mínimo que envolve toda a extensão do objeto.

Figura 8 - Exemplos de como são estabelecidos os valores de perímetro l (em azul) e *bounding box* b (em verde) dos objetos de imagem

Objeto	Perímetro l	bounding box b	Objeto	Perímetro l	bounding box b

Fonte: Adaptado de PINHO (2005)

$$cp = \frac{l}{\sqrt{n}} \quad (35)$$

$$sv = \frac{l}{b} \quad (36)$$

A heterogeneidade de forma é expressa por:

$$h_{forma} = w_{cmpct} \cdot h_{cmpct} + (1 - w_{cmpct}) \cdot h_{suave} \quad (37)$$

sendo:

w_{cmpct} – peso atribuído à compacidade do objeto, $0 \leq w_{cmpct} \leq 1$

$$h_{cmpct} = n_{obj3} \cdot cp_{obj3} - (n_{obj1} \cdot cp_{obj1} + n_{obj2} \cdot cp_{obj2}) \quad (38)$$

$$h_{suave} = n_{obj3} \cdot sv_{obj3} - (n_{obj3} \cdot sv_{obj3} + n_{obj3} \cdot sv_{obj3}) \quad (39)$$

Segundo Feitosa et al. (2007), o resultado da segmentação depende, exclusivamente, de parâmetros definidos pelo analista, sendo estes: parâmetro de escala (e), pesos atribuídos às diferentes bandas espectrais w_c , peso da componente cor w_{cor} , e peso da componente de compacidade w_{cmpct} . Além disso, a definição do valor de e reflete diretamente no tamanho dos objetos de imagem que serão gerados, valores altos produziram objetos grandes (BO; HAN, 2010).

De acordo com Pinho (2005), a utilização de segmentação multirresolução possibilita a criação de uma rede hierárquica de objetos, ou seja, são aplicados diversos níveis de segmentação a imagem, gerando assim, além dos objetos, subobjetos e superobjetos. Há duas abordagens que podem ser admitidas para a hierarquização dos objetos (PINHO, 2005):

- *Bottom-up*: a segmentação inicia-se pelo nível mais detalhado e posteriormente outros elementos são agregados, conforme o nível hierárquico;
- *Top-down*: inicia-se com superobjetos e ocorre a fragmentação desses em objetos mais detalhados.

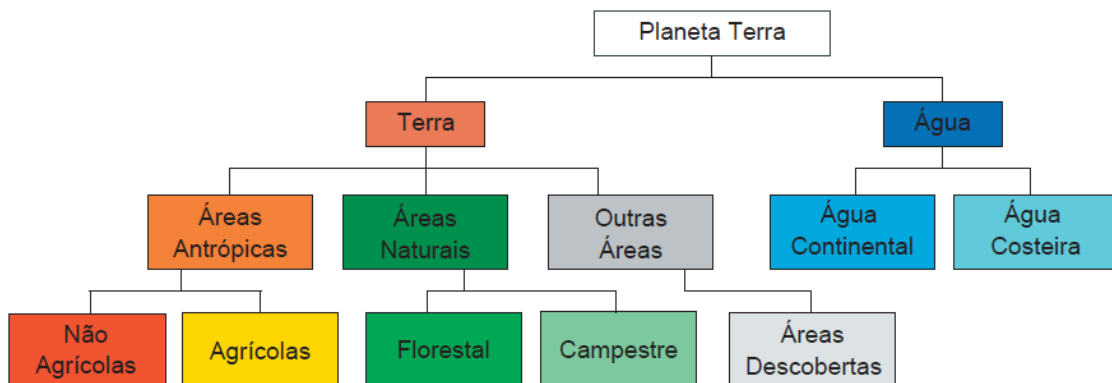
2.4.2 Redes Hierárquicas de Classes

As redes hierárquicas de classes consistem em apresentar relações entre coberturas e usos de terra, conforme sua complexidade de organização em níveis de informação (LANG, 2007). Com isso, o nível de informação tem relação direta com a especificidade do objeto. Devido a isso, o IBGE – Instituto Brasileiro de Geografia e Estatística (2013) recomenda a realização de mapeamentos em diferentes níveis de informação a fim de que esses possam ser utilizados nas mais diversas aplicações.

Há um esforço internacional voltado ao desenvolvimento de um sistema padrão para redes hierárquicas para classificação de imagens de sensoriamento remoto. Os sistemas de classificação mais comuns são os propostos pela USGS (*United States Geological Survey*) (ANDERSON et al., 1976), pela União Europeia (EUROPEAN ENVIRONMENT AGENCY, 1995) e pela FAO (*Food and Agriculture Organization of the United Nations*) (DI GREGORIO; JANSEN, 2000). Para o Brasil, o IBGE (IBGE, 2013), propôs um sistema de classificação para mapeamento temático nas escalas de 1:250.000 e 1:100.000, o qual apresenta 3 níveis de informação.

A Figura 9 mostra uma possível rede hierárquica de classes em dois níveis utilizando o sistema de classificação proposto pelo IBGE (2013). É possível notar que conforme se aumenta o nível de informação, mais específica se torna a classe. No nível I, são apresentadas cinco categorias globais, que atenderão às necessidades de usuários interessados em informações regionais e inter-regionais. Já o nível II, fornecerá um mapeamento voltado aos usuários interessados em escala regional.

Figura 9 – Exemplo de uma rede hierárquica de classes de cobertura da terra



Fonte: IBGE (2013)

2.4.3 Classificação Orientada a Objetos

Após a geração dos objetos de imagem e a estruturação das redes hierárquicas, a classificação dos objetos é realizada por meio de regras de decisão. Nessa etapa, é necessário que o analista tenha conhecimento prévio sobre as características que melhor discriminam os objetos em relação às classes desejadas. Além disso, deve-se definir como serão atribuídas classes aos objetos.

Uma das formas de atribuição de classes é por meio de Funções de Pertinência *fuzzy*, as quais possibilitam que um objeto tenha associação a mais de uma classe com diferentes valores de probabilidade, sendo o objeto atribuído àquela classe que apresentar a maior pertinência (PINHO, 2005). Além disso, há também a opção por uso de funções *booleanas*, às quais retornam valor 0 (não pertence) e 1 (pertence).

A elaboração de regras para a classificação dos objetos pode considerar a natureza de sete características de objeto: valores radiométricos extraídos das bandas espectrais, geometria, posição, textura, hierarquia, atributos temáticos e nuvem de pontos. O Quadro 3 mostra os atributos de cada grupo de característica de objetos.

Quadro 3 – Atributos inerentes às características de objeto

Grupo	Atributos
Valores extraídos das bandas espectrais	Média, desvio padrão, assimetria, moda, quantil, matiz, saturação e intensidade.
Geometria	Extensão, forma, ao superobjeto, relacionados ao polígono e ao esqueleto.
Posição	Distância e coordenadas
Textura	Variabilidade espectral e geométrica, medidas de Haralick.
Hierarquia	Associados com a relação do objeto com seus super e subobjetos.
Atributos Temáticos	Sobreposição máxima ou mínima de polígonos temáticos e número de objetos temático sobreposto.
Nuvem de pontos	Intensidade, coordenadas X e Y, elevação, número de retornos, vermelho, verde, azul, número de pontos e distância à câmera.

Fonte: Adaptado de TRIMBLE (2014)

Além disso, existem as características relacionadas à classe que são aplicadas pós-classificação. Essas características são consideradas como globais, pois não estão relacionadas a objetos de imagem individualmente (TRIMBLE, 2014). Elas se caracterizam por:

- **Relações a objetos vizinhos:** descrevem um objeto por sua relação com outros de uma dada classe no mesmo nível de imagem;
- **Relações a subobjetos:** descrevem a relação de um objeto com os objetos de imagem de sua vizinhança, existentes em um nível inferior de imagem;
- **Relações a superobjetos:** descrevem a relação de um objeto com os objetos de imagem de sua vizinhança existentes em um nível superior de imagem;
- **Relações a classificação:** verificação sobre a atual ou potenciais classes de um objeto de imagem.

2.5 Qualidade de Dados Espaciais

Nos últimos anos, devido a popularização de aplicativos de SIG, a utilização de produtos cartográficos vem sendo consideravelmente ampliada, tanto por organizações públicas como privadas, nos procedimentos que necessitam de tomada de decisão. Portanto, a análise da qualidade de dados espaciais é imprescindível, visto que estas representam a realidade do local onde foram registrados (LÓPEZ, 2002).

Os dados espaciais são aqueles que, além de representar atributos de uma feição, também apresentam o posicionamento em que essa se encontra. A posição de um dado pode ser expressa tanto por coordenadas unidimensionais (distância ao longo de um transepto), bidimensionais (sobre uma superfície plana) ou tridimensionais (superfície física da Terra) (STEIN; VAN OORT, 2006).

Segundo Veregin (1999), a definição de qualidade de dados espaciais não é trivial, pois é expressa por métricas não tangíveis como ‘completude’ e ‘consistência’, ao contrário de produtos manufaturados que podem ser avaliados por meio de medidas físicas.

Apesar de qualidade e erro serem conceitos que aparentam ter significado similar, suas definições apresentam distinção. Qualidade possui a natureza de ser relativa e utilitária, pois visa analisar se os dados estão adequados para o uso considerando a finalidade proposta (VAN OORT, 2005). Enquanto que erro está relacionado à diferença ou discrepância, ou seja, a distância de um atributo do dado ao valor tido como referência ou de controle (LÓPEZ, 2002).

De acordo com a ISO 19157:2013 (ISO, 2013), há seis elementos usados na descrição de qualidade de dados espaciais:

- **Completude:** relacionada ao excesso ou à falta de feições;
- **Consistência Lógica:** grau de aderência a regras lógicas, quanto a estrutura dos dados, atribuição e relações;
- **Acurácia Posicional:** acurácia com que uma feição é representada em um determinado sistema de referência espacial;
- **Acurácia Temática:** acurácia que representa a exatidão de atributos;
- **Qualidade Temporal:** qualidade de atributos temporais e relações temporais das feições;
- **Usabilidade:** estabelece a quais aplicações específicas a informação é adequada para uso.


De acordo Riazanoff e Santer (2006), a qualidade de informação em cada *pixel* de uma imagem tem a capacidade de prover informações radiométricas e temáticas confiáveis sobre a superfície registrada. Sendo assim, quando se utiliza imagens com a finalidade de extrair informações para a detecção de mudanças por meio de classificação de cenas tomadas em diferentes épocas, é necessário considerar os elementos de qualidade temática e posicional.

2.5.1 Acurácia Posicional de Imagens

A qualidade posicional de uma imagem é dependente da geometria com que essa foi adquirida. Sendo assim, uma compreensão de como é orientado o sistema de coordenadas de uma imagem e como ela é especificada é de suma importância.

A orientação do sistema de coordenadas imagem é levogiro, com origem na extremidade superior esquerda (Figura 10). Sendo as coordenadas de um *pixel* definidas pela linha e coluna que este ocupa na imagem.

Figura 10 – Representação do sistema de coordenadas linha (l) e coluna (p) de uma imagem




Fonte: RIAZANOFF; SANTER (2006)

Os elementos de imagem podem ser codificados para que suas coordenadas sejam expressas como sendo geodésicas. Usualmente, a referência de geocodificação de coordenadas de imagem considera o centro de massa do *pixel*. Contudo, algumas codificações consideram o canto superior esquerdo. Conseqüentemente, a falta de conhecimento de como são expressas as coordenadas acarretam uma incerteza de 0,5 *pixel* em ambas direções paralelas ao referencial, ou seja, um total de $\sqrt{2}/2$ *pixels* (RIAZANOFF; SANTER, 2006).

Outra fonte de erro ocorre quando há variação de geometria na aquisição de quadros em épocas diferentes. Nesse caso, ao se analisar feições homólogas entre duas ou mais imagens multitemporais, é possível perceber que há deslocamento do elemento da paisagem entre as épocas. Com isso, os objetos são representados de forma distorcida. As distorções estão relacionadas com a orientação exterior, a qual é dada pela posição geodésica (X, Y) e os ângulos de rotação sobre os eixos ω , φ e κ , de orientação da plataforma durante a aquisição de imagens. Os efeitos decorrentes da orientação exterior acarretam em translação, rotação e variação de escala de objetos no quadro, como pode ser visto na Figura 11.

Figura 11 – Efeitos na aquisição de imagem ocasionados pela orientação exterior da plataforma de aquisição. a) translação nas coordenadas X e Y, b) rotação sobre o eixo ω , c) rotação sobre o eixo ϕ , d) rotação sobre o eixo κ



Fonte: RIAZANOFF; SANTER (2006)

Na análise de imagens multitemporais com a finalidade de detectar mudanças ocorridas sobre a cobertura terrestre, é imprescindível que o sistema de coordenadas das imagens seja compatível. Pois assim, as feições que não sofreram modificação ao longo do tempo estarão sobrepostas e as mudanças ocorridas serão detectadas de forma mais confiável, visto que se reduzirá os casos de falsa detecção. Portanto, é necessário adotar um único sistema referencial de coordenadas para representar todas as imagens.

Existem duas abordagens para a compatibilidade do sistema de duas ou mais imagens, o georreferenciamento e o registro. A realização do primeiro se dá a partir da mensuração de coordenadas geodésicas de objetos fotoidentificáveis. E por seguinte, são observadas as coordenadas de imagem dos mesmos pontos que tiveram sua posição determinada em campo. Por fim, a partir de um modelo matemático as coordenadas de imagem são transformadas em coordenadas geodésicas (RICHARDS, 2013). Por outro lado, o registro de imagens é independente de levantamento de coordenadas dos pontos em campo. Visto que, esse método visa a compatibilidade de coordenadas de imagem entre duas cenas, sendo que, uma delas é tomada como referência para a outra. Portanto, são observadas as posições de objetos homólogos entre os quadros. Finaliza-se com aplicação de um modelo

matemático para a transformação para o sistema de coordenadas da imagem de referência (SCHOWENGERDT, 2007).

A transformação de coordenadas de imagens, tanto no georreferenciamento como no registo, é realizada por meio de reamostragem do valor de ND dos *pixels*. Dentre as diversas abordagens existentes para a reamostragem, a mais indicada é o ‘vizinho mais próximo’, pois neste método se conserva as características dos NDs registrados na aquisição das imagens (RICHARDS, 2013). Com isso, não há alterações nas estatísticas da imagem.

2.5.2 Acurácia Temática

De acordo com Congalton e Green (1999) há quatro motivos para a realização da avaliação de qualidade temática de mapas elaborados a partir de sensoriamento remoto: (1) por curiosidade, desejo de saber quão bom é o produto; (2) melhorar a qualidade do mapa, identificando e corrigindo fontes de erros; (3) comparação entre diversos métodos, algoritmos, analistas ou interpretadores; e (4) conhecer a qualidade do produto para considerá-la no processo de tomada de decisão.

A ferramenta básica para análise da acurácia temática é matriz de erro (exemplificada na Tabela 1), a partir da qual é possível estimar a acurácia global do produto temático (Equação 40), bem como as acurácias do usuário e do produtor por classe (Equações 41 e 42, respectivamente). A matriz de erro expressa o número de *pixels* ou área associada a uma classe específica em relação a uma referência, tomada como verdade terrestre. Ou seja, indica a concordância entre o resultado da classificação e o conjunto de referência (CONGALTON; GREEN, 1999).

Tabela 1 - Exemplo da estrutura da matriz de erro, em que M se refere ao número de classes e n indica o número de elementos amostrais. N é o tamanho da amostra.

		Referência				
		1	2	...	M	Total
Classificação	1	n_{11}	n_{12}	...	n_{1M}	n_{1+}
	2	n_{21}	n_{22}	...	n_{2M}	n_{2+}
	⋮	⋮	⋮	⋮	⋮	⋮
	M	n_{M1}	n_{M2}	...	n_{MM}	n_{M+}
	Total	n_{+1}	n_{+2}	...	n_{+M}	N

Fonte: Adaptado de Congalton; Green (1999)

$$\alpha_{global} = \frac{\sum_{i=1}^M n_{ii}}{N} \quad (40)$$

$$\alpha_{usuário} = \left(\frac{n_{ii}}{n_{i+}}\right) \quad (41)$$

$$\alpha_{produtor} = \left(\frac{n_{ii}}{n_{+i}}\right) \quad (42)$$

sendo n_{ii} o elemento da linha $i+$, coluna $+i$ da matriz de erro, N o número total de elementos amostrais do conjunto de referência e M o número de classes.

Para a elaboração da matriz de erro, é necessário dispor de uma referência de campo para confrontar com o resultado da classificação. A quantidade de amostras necessárias é dada pela Equação 43, na qual são informados o nível de significância (α) e a precisão desejada (β) a ser alcançada.

$$N = \chi^2_{(1,1-\alpha/M)} / 4\beta^2 \quad (43)$$

em que: $\chi^2_{(1,1-\alpha/M)}$: valor identificado na distribuição Qui-quadrado para 1 grau de liberdade e $(1-\alpha/M)$ nível de confiança.

Além das medidas de qualidade temática expressas nas Equações 40, 41 e 42, outra medida usual é o índice de concordância *Kappa* (\hat{K}). Segundo Viera e Garret (2005), o coeficiente *Kappa* vem sendo utilizado para a avaliação de independência entre duas ou mais observações de um mesmo fenômeno. Este índice é uma medida de qualidade de uma classificação, sendo derivado da matriz de erro e livre de qualquer viés resultante da concordância ao acaso entre a classificação e a verdade terrestre (RICHARDS, 2013). Utilizando os termos expressos na matriz de erro (Tabela 1), o índice de concordância *Kappa* pode ser calculado por meio da Equação 44.

$$\hat{K} = \frac{n \sum_{i=1}^M n_{ii} - \sum_{i=1}^M n_{+i} n_{i+}}{n^2 - \sum_{i=1}^M n_{+i} n_{i+}} \quad (44)$$

A análise de *Kappa* tem sido amplamente utilizada pela comunidade de Sensoriamento Remoto pois permite estabelecer comparações entre métodos de classificação,

entre outros, por meio da variância de *Kappa*. Segundo Congalton e Green (1999), a variância relacionada ao índice de concordância *Kappa* é calculada a partir do método Delta e indicada pela Equação 45.

$$v\hat{a}r(\hat{K}) = \frac{1}{n} \left\{ \frac{\theta_1(1-\theta_1)}{(1-\theta_1)} + \frac{2(1-\theta_1)(2\theta_1\theta_2-\theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4-4\theta_2^2)}{(1-\theta_1)^4} \right\} \quad (45)$$

em que:

$$\begin{aligned} \theta_1 &= \frac{1}{n} \sum_{i=1}^M n_{ii} \\ \theta_2 &= \frac{1}{n^2} \sum_{i=1}^M n_{+i}n_{i+} \\ \theta_3 &= \frac{1}{n^2} \sum_{i=1}^M n_{ii}(n_{+i}n_{i+}) \\ \theta_4 &= \frac{1}{n^3} \sum_{i=1}^M \sum_{j=1}^M n_{ij}(n_{+i}n_{j+})^2. \end{aligned}$$

O valor de \hat{K} é calculado assumindo que a disposição espacial dos elementos amostrais obedece a distribuição normal e que o tamanho da amostra seja grande (CONGALTON; GREEN, 1999). Portanto, pode ser utilizado para o teste de significância de uma matriz de erro para determinar se a concordância entre a classificação e a referência de campo é significativamente maior do que 0, demonstrando assim que o produto obtido é melhor do que a atribuição de forma aleatória de classes aos dados de sensoriamento remoto. O teste de significância da matriz de erro é expresso pela Equação 46.

$$Z = \frac{\hat{K}}{\sqrt{v\hat{a}r(\hat{K})}} \quad (46)$$

sendo que Z é padronizado e tem distribuição normal. Dada a hipótese nula $H_0 : K = 0$, e a alternativa $H_1 : K \neq 0$, H_0 é rejeitada se $Z \geq Z_{\alpha/2}$, para $\alpha/2$ e nível de confiança do teste bicaudal.

Além disso, a partir do \hat{K} é possível determinar se duas matrizes de erro são significativamente diferentes. O teste permite comparar estatisticamente dois analistas, o mesmo analista ao longo do tempo, dois métodos, dois tipos de imagens ou mesmo duas datas de imagens e obter qual produz informação de forma mais acurada (CONGALTON; GREEN, 1999). O teste estatístico para a verificação se duas matrizes de erro são estatisticamente é demonstrado na Equação 47.

$$Z = \frac{|\hat{K}_1 - \hat{K}_2|}{\sqrt{\hat{v}\hat{a}r(\hat{K}_1) + \hat{v}\hat{a}r(\hat{K}_2)}} \quad (47)$$

em que Z é padronizado e normalmente distribuído. Dado que a hipótese nula $H_0 : (K_1 - K_2) = 0$, e a alternativa $H_1 : (K_1 - K_2) \neq 0$, H_0 é rejeitada se $Z \geq Z_{\alpha/2}$.

3 MATERIAIS E MÉTODOS

3.1 Área de Estudo

O reservatório Jaguari-Jacareí foi selecionado para o presente estudo de caso e seu entorno definiu a área de estudo, conforme indicado na Figura 12. Esse reservatório está localizado na divisa entre os municípios paulistas de Bragança Paulista, Vargem, Joanópolis e Piracaia. O Jaguari-Jacareí é a maior represa do Sistema Cantareira, principal fornecedora de água à Região Metropolitana de São Paulo. Sua área e volume máximo são, respectivamente, 1230 km² e 808,12 hm³ (ou 808,12 bilhões de litros, já que 1 hm³ = 1 milhão de m³ = 1 bilhão de litros). O início da construção do reservatório deu-se no ano de 1977 e sua operação iniciou-se no ano de 1982 (ANA, 2013).

Figura 12 - Delimitação da área de estudo em imagem OLI/Landsat-8 adquirida no dia 02 de junho de 2014 (composição colorida com as bandas: 2B, 3G, 4R), bem como sua localização no estado de São Paulo



Fonte: USGS

O Sistema Cantareira, administrado pela Companhia de Saneamento Básico do Estado de São Paulo (Sabesp), inclui, além do reservatório Jaguari-Jacareí, as represas Cachoeira, Atibainha, Paiva Castro e Águas Claras, sendo que as duas primeiras, junto com o Jaguari-Jacareí, formam um sistema equivalente (Figura 13) que comporta até 973,94 hm³ (ANA, 2015b).

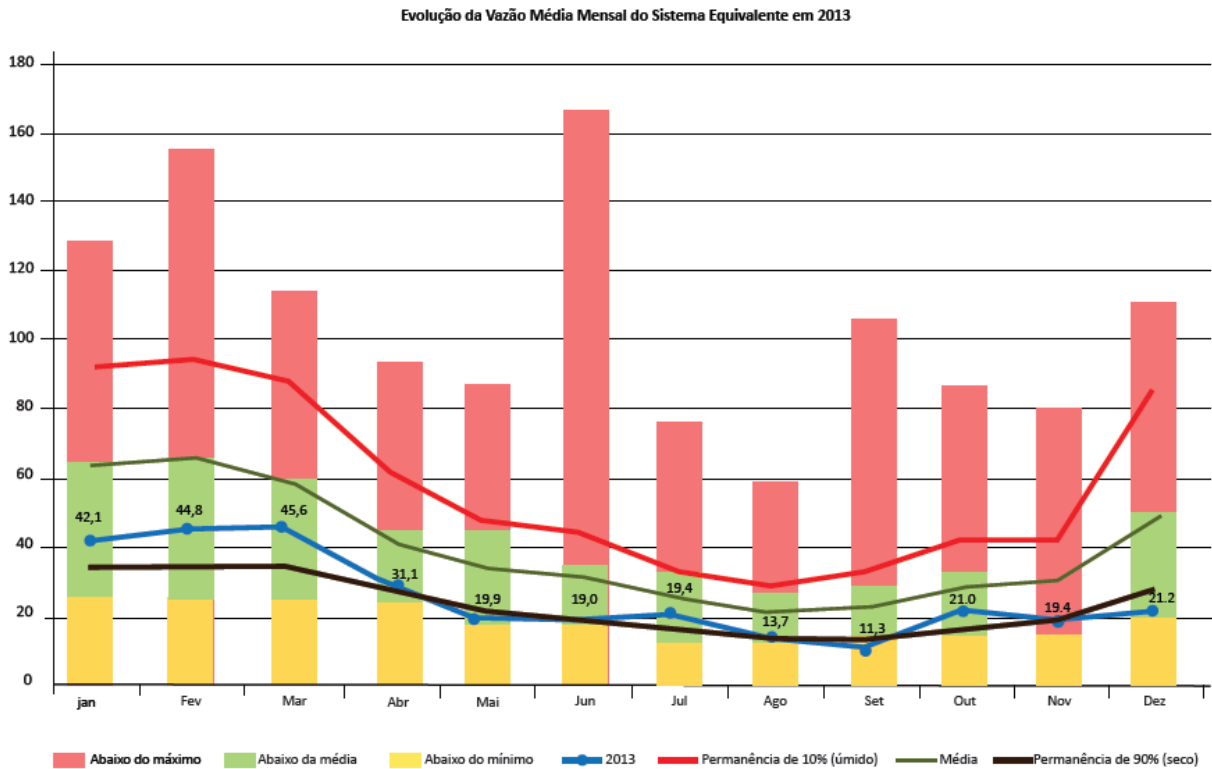
Figura 13 - Estrutura de organização do Sistema Cantareira



Fonte: ANA (2015a)

De acordo com a ANA (2015b) em 2013, a vazão do sistema equivalente do Cantareira foi inferior, mensalmente, que a média histórica da região (Figura 14). Além disso, os anos de 2012 e 2013 estão entre os quatro anos de menor vazão dos rios Jaguari e Jacareí na região, sendo que, os outros dois anos que compõem esse grupo são anteriores a instalação dos reservatórios (1953 e 1969). Apesar de não haver documentação oficial sobre a vazão média mensal no ano de 2014, na página da Sabesp há indicação que as médias mensais de pluviometria foram menores que nos anos anteriores. Portanto, no ano de 2014, o fornecimento foi ainda mais prejudicado.

Figura 14 - Vazão do sistema equivalente do Cantareira no ano de 2013



Fonte: ANA (2015b)

Dos reservatórios presentes no Sistema Cantareira, o que apresentou o cenário mais drástico durante a crise hídrica, entre 2013 e 2015, foi o Jaguari-Jacareí. Devido à escassez de água na área na represa, no dia 16 de maio de 2014, foi autorizada a captação da primeira cota da reserva técnica, ampliando a capacidade de abastecimento em 182,5 milhões de litros. No dia de 24 de outubro de 2014, a segunda cota da reserva técnica começou a ser captada, o que forneceu 105 bilhões de litros adicionais (Sabesp, 2015).

3.2 Materiais


Para o desenvolvimento desta pesquisa foram utilizadas imagens multiespectrais obtidas pelo sistema orbital RapidEye e os dados necessários para gerar a representação do relevo submerso do reservatório Jaguari-Jacareí. O modelo do relevo submerso foi produzido pela combinação de dados de profundidade obtidos por levantamento batimétrico, disponibilizados pela Sabesp e do Modelo Digital de Superfície (MDS) AW3D30 (*ALOS World 3D 30m mesh*, disponibilizado pela JAXA (Agência Japonesa de Exploração Aeroespacial)), além dos *softwares* ENVI 5.2, ArcGIS 10 e IDRISI Selva 17.0, que foram

utilizados para o pré-processamento das imagens, classificação, avaliação de acurácia e estimação de volume do reservatório.

3.2.1 Imagens RapidEye

Foram utilizadas quatro imagens RapidEye ortorretificadas para a composição integral da área de estudo, como mostra a Figura 15, tomadas em 2013 e 2014 (antes e durante a crise de abastecimento de 2014). As imagens utilizadas nesta pesquisa foram cedidas pelo Ministério do Meio Ambiente, por meio do portal 'GeoCatálogo', que tem o objetivo de disponibilizar imagens multiespectrais de alta resolução espacial, cobrindo todo o Brasil, a órgãos públicos federais, estaduais e municipais. O acesso às imagens dá-se pela página *web* <<http://geocatalogo.mma.gov.br/>>.

Figura 15 - Mosaico das quatro imagens RapidEye que compõem a área de estudos, referentes ao ano de 2013.



O sistema RapidEye é composto por cinco satélites pertencentes ao mesmo plano orbital, sendo que o sensor registra os dados da superfície terrestre em cinco bandas espectrais: azul (440-510 nm), verde (520-590 nm), vermelho (630-685 nm), *red edge* (690-730 nm) e infravermelho próximo (760-850 nm). O sensor é do tipo *pushbroom* e adquire dados tanto no nadir como *off-nadir*, sendo que no primeiro caso o tempo de revisita é de 5,5 dias e possibilitando aquisição diária em visada *off-nadir*. O GSD (*Ground Sample Distance*) do sensor é 6,5 metros na aquisição no nadir (PLANET, 2016).

As imagens RapidEye são comercializadas em três níveis de processamento, sendo que o Ministério do Meio Ambiente disponibiliza o produto 3A, que incorpora correções geométricas, dos efeitos de inclinação da plataforma de aquisição e, além disso, são utilizados pontos de controle de terreno e modelos digitais de superfície (MDS) precisos para a geração de ortofotos, na projeção UTM no sistema de referência WGS 84. Com isso, o tamanho de pixel da imagem ortorretificada é de 5 metros e sua acurácia espacial global de 10 metros. Em algumas regiões, a acurácia pode ser melhor do que a esperada, condicionada à disponibilidade de pontos de controle ou MDSs mais acurados (PLANET, 2016).

3.2.2 Modelo do Relevo Submerso

Antes de detalhar os dados utilizados para a representação do relevo submerso, é de importante definir os métodos de representação de superfícies. Segundo El-Sheimy, Valeo e Habib (2005), a superfície da Terra pode ser representada a partir de pontos com coordenadas X, Y e Z conhecidas. Sendo que, existem duas abordagens de representação:

- **Modelo Digital de Superfície:** esse modelo é criado a partir das alturas máximas dos objetos da paisagem em relação a um *datum* (incluindo telhado de edificações, dosséis de árvores, etc.),
- **Modelo Digital de Terreno:** essa classe de modelos é construída por meio de pontos de dados amostrados que representam a distribuição espacial de vários tipos de informação no terreno.

Para a estimação de volume do reservatório foi necessário um modelo digital de terreno (MDT) submerso. Na geração desse MDT foram utilizados dados de profundidade do levantamento batimétrico do reservatório, fornecidos pela Sabesp e utilizados pela instituição

na determinação do nível do reservatório nas estimativas oficiais do volume de água disponível e o modelo digital de superfície AW3D30 (*ALOS World 3D 30m mesh*). Esse MDS foi necessário pelo fato dos dados obtidos por batimetria disponibilizados apresentam observações somente até a cota (terminologia adotada para se referir a altitude ortométrica) de 830,13 metros. Contudo, no ano de 2013, o nível de água estava superior a essa cota e foi necessário complementar a informação referente ao releve submerso para as altitudes mais elevadas.

3.2.2.1 Dados de Profundidade Obtidos por Batimetria

Os dados obtidos por meio de levantamento batimétrico utilizados nessa pesquisa foram gentilmente disponibilizados pela Sabesp. Esses dados, resultantes de um levantamento batimétrico realizado em 2008, consistem de medidas de profundidade obtidas em 154.516 posições do reservatório de Jaguari-Jacareí. As posições de aquisição foram determinadas a partir da técnica DGPS e projetadas ao sistema UTM, *datum* horizontal SAD-69. Após a aquisição das profundidades, foram determinadas as altitudes do relevo submerso do reservatório, sendo utilizada como referência de nível a RN9301L, localizada em Paiva Castro – SP, tendo como *datum* vertical o marégrafo de Imbituba – SC.

De acordo com El-Hattab (2014), o uso de dados batimétricos para a geração de MDTs podem alcançar a acurácia vertical de 0,16 metros, dependendo do batímetro utilizado para a determinação de profundidade. Por outro lado, o método de posicionamento por DGPS possui acurácia variando entre 1 e 3 metros (LAPUCHA; MAYNARD, 1992). Vale ressaltar que, esses dados são utilizados pela Sabesp para a estimativa do volume de água, divulgado diariamente em sua página *online* <<http://site.sabesp.com.br/site/interna/Default.aspx?secaoId=553>>.

Pelo fato dos pontos obtidos por batimetria estarem referenciados ao *datum* horizontal SAD-69 e os demais dados usados nesta pesquisa utilizarem como referência o sistema WGS-84, foi necessário aplicar um deslocamento sistemático aos dados batimétricos para integrá-lo ao conjunto de dados. Segundo IBGE (1989), a conversão de *datum* é realizada a partir da transformação de referenciais terrestres, sendo que os parâmetros utilizados na transformação de SAD-69 para WGS-84 foram:

$$\Delta X = -66,87 \text{ metros}$$

$$\Delta Y = 4,37 \text{ metros}$$

$$\Delta Z = -38,52 \text{ metros}$$

3.2.2.2 Imagens AW3D30

O AW3D30 é um MDS produzido e distribuído pela Agência de Exploração Aeroespacial Japonesa (JAXA), o qual é derivado de imagens pancromáticas do sensor PRISM (*Panchromatic Remote-sensing Instrument for Stereo Mapping*), apresentando resolução espacial de 2,5 metros e esteve embarcado no satélite ALOS (*Advanced Land Observing Satellite*) durante o período que esteve ativo, entre os anos de 2006 e 2011 (TADONO *et al.*, 2016).

A geração do MDS do AW3D30 é feita a partir da triangulação semi-automática de modelos estereoscópicos de imagens PRISM, produzindo-se uma estrutura matricial com resolução espacial de 5 metros e cujos Números Digitais representam a elevação das posições geográficas dos *pixels*, denominado como AW3D. Embora esse produto não seja disponibilizado de forma livre, existe uma versão gratuita, com resolução espacial redimensionada para 30 metros (TADONO *et al.*, 2016). Nesta dissertação foi utilizado o produto disponibilizado gratuitamente, com resolução espacial de 30 metros. A acurácia do AW3D30 é de, aproximadamente, 5 metros tanto para o plano horizontal como para o vertical. A validação do produto foi realizada a partir de 5121 alocados em 127 modelos (*tiles*) distribuídos pelo globo terrestre (JAXA, 2017).

Os dados AW3D30 estão representados em altitude elipsoidal, enquanto que, os batimétricos em altitude ortométrica. Essas grandezas precisam ser compatibilizadas, pois a altitude elipsoidal refere-se a distância entre a superfície terrestre e o elipsóide do sistema de referência, enquanto que a altitude ortométrica é a distância da superfície terrestre até o geóide. A diferença entre as altitudes elipsoidal e ortométrica define ondulação geoidal (MONICO, 2008) e, como é necessário que se adote a mesma grandeza para uma estimativa mais acurada do volume do reservatório, foi realizada a transformação da altitude elipsoidal para ortométrica, utilizando a Equação 48.

$$H \cong h - N \quad (48)$$

sendo:

H – altitude ortométrica;
h – altitude elipsoidal;
N – ondulação geoidal.

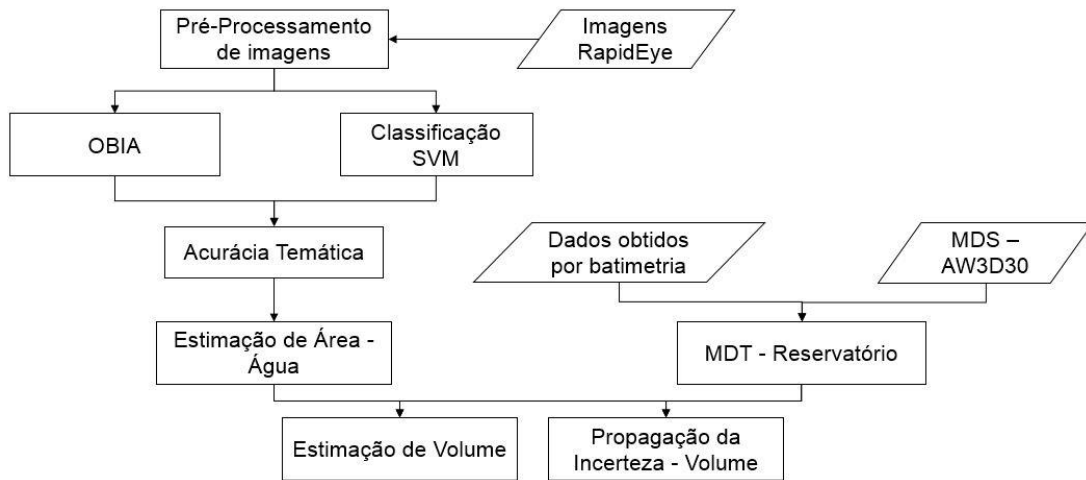
Para a correção da transformação de altitude elipsoidal em ortométrica, considerou-se que o elipsoide e o geóide são paralelos na área de estudo e, com isso, foi adotado um valor constante para ondulação geoidal ao longo de todo o reservatório. A ondulação geoidal utilizada para a transformação no local de estudo foi de -2,70 metros. Esse procedimento foi realizado por meio do software livre MAPGEO 2015, disponibilizado pelo IBGE, o qual obtém a ondulação geoidal, a partir de interpolação de um modelo geoidal com resolução de 10' (dez segundos de arco).

3.3 Desenvolvimento Metodológico

A abordagem metodológica desenvolvida nesta pesquisa foi suportada pela hipótese de que os produtos obtidos por meio de classificação de imagens, utilizando-se de SVMs e orientação a objeto, possuem acurácia adequada para extração de informações espaciais que viabilize a estimativa, também acurada, do volume. Com isso, definiu-se como caso de estudo a redução na capacidade de armazenamento do reservatório Jaguari-Jacareí, durante a crise hídrica ocorrida entre os anos de 2013 e 2015.

A Figura 16 apresenta o conjunto de atividades desenvolvidas para atingir os objetivos propostos: (i) obtenção das imagens RapidEye a partir do portal 'GeoCatálogo' do MMA; (ii) pré-processamento das imagens, incluindo o recorte da área de estudo, registro e mosaico das cenas; (iii) classificação de imagens de 2013 e 2014 utilizando uma abordagem por *pixel* (SVM) e orientação a objeto; (iv) avaliação de acurácia temática das classificações resultantes; (v) estimativa da área do reservatório para os diferentes resultados de classificação; (vi) cálculo do volume do reservatório e propagação de erros associados à estimativa do volume, para cada cenário.

Figura 16 – Fluxograma das atividades desenvolvidas na pesquisa



3.3.1 Pré-Processamento das Imagens RapidEye

A etapa de pré-processamento consiste em realizar operações sobre as imagens para que estas estejam adequadas para aplicar técnicas de extração de informações. No caso desse estudo, foram realizados o recorte da área de interesse na imagem, registro geométrico e mosaico.

Para a composição da área total, em cada tempo de estudo (2013 e 2014) foram necessárias quatro cenas RapidEye, obtidas também em diferentes datas, conforme indicado na Tabela 2. Esses diferentes momentos de aquisição dentro do mesmo ano definiram variações radiométricas no mesmo tipo de alvo, principalmente, o corpo d'água, devido às diferentes condições atmosféricas e ambientais no momento de cada tomada de imagem. Desse modo, cada cena foi classificada individualmente e, no final, foi realizado o mosaico.

Registro é o processo de realizar a concordância espacial entre feições homólogas identificadas em duas ou mais imagens (SCHOWENGERDT, 2007), adotando uma das cenas como referência para a transformação geométrica das demais. Diversas aplicações de sensoriamento remoto necessitam de registro de imagens tomadas em épocas diferentes, entre elas a detecção de mudanças. No presente caso, as imagens de referências foram do ano de 2013 e as imagens submetidas a uma transformação linear foram aquelas tomadas em 2014. O número de pontos de controle utilizados e o resíduo da transformação são mostrados também na Tabela 2.

Tabela 2 - Data de tomada das cenas RapidEye que compõem a área de estudos, para cada ano da análise, número de pontos de controle usados no registro e resíduo da transformação.

Quadrante	Ano		Registro	
	2013	2014	Nº pontos de controle	Resíduo (<i>pixels</i>)
A	09/09/2013	30/07/2014	20	0,4542
B	09/09/2013	30/07/2014	20	0,5124
C	09/09/2013	30/07/2014	19	0,3083
D	13/10/2013	10/10/2014	20	0,4340

*Quadrante especifica cada cena que compõe a área de estudos, conforme mostrado na Figura 7.

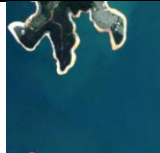

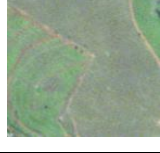


Mosaico é o processo de conectar imagens adjacentes para representar uma área geográfica, que se estende além de uma cena. Esse processo, realizado no software ENVI 5.1¹, considerou que as imagens RapidEye fornecidas pelo MMA possuem sobreposição de 4% entre os quadros, de modo que o mosaico foi elaborado levando em conta o posicionamento geográfico das cenas, ou seja, baseou-se em georreferenciamento. Como especificado anteriormente, foi realizado o mosaico das imagens classificadas já que, com a normalização radiométrica das imagens que compõem a área de estudos, não é possível homogeneizar as variações radiométricas intrínsecas de alguns alvos (como corpo d'água).

3.3.2 Definição das Classes

As classes de cobertura da terra utilizadas neste trabalho foram estabelecidas por meio de consulta aos planos diretores dos municípios de Bragança Paulista, Piracaia, Vargem e Joanópolis (PREFEITURA MUNICIPAL DE BRAGANÇA PAULISTA, 2007; PREFEITURA MUNICIPAL DE PIRACAIA, 2007; PREFEITURA MUNICIPAL DE VARGEM, 2000; CÂMARA MUNICIPAL DA INSTÂNCIA TURÍSTICA DE JOANÓPOLIS, 2006), imagens históricas disponíveis no GoogleEarthTM e a interpretação das próprias imagens RapidEye. As classes de cobertura da terra utilizadas e suas definições estão presentes no Quadro 4.

¹ Programa computacional produzido pela empresa Exelis, voltado à visualização, exploração, análise e apresentação de dados de Sensoriamento Remoto/SIG.

Quadro 4 - Classes a serem utilizadas na pesquisa, suas definições e recortes de exemplos em composição de cor verdadeira

Classe	Definição	Exemplo (B1G2R3)
Água (Ag)	Reservatório Jaguari-Jacareí.	
Vegetação arbórea (VA)	Áreas cobertas por árvores.	
Vegetação rasteira (VR)	Áreas cobertas por vegetação de pequeno porte.	
Solo exposto (SE)	Áreas cobertas por solo exposto, sem vegetação.	
Área impermeável (Im)	Áreas cobertas por telhados, infraestrutura do reservatório, pavimentação e rocha exposta.	

3.3.3 Classificação das imagens RapidEye

Cada uma das quatro imagens RapidEye que compõem a área de estudo foi classificada individualmente, utilizando ambas abordagens de análise (pixel – SVM e objeto – OBIA), para as tomadas de imagens de 2013 e 2014.

Como o SVM é um método de classificação supervisionado foi necessária a aquisição de um conjunto de treinamento que fosse representativo de cada classe descrita no Quadro 4. A classificação foi feita no software ENVI 5.1, sendo que as amostras de treinamento foram adquiridas em cada imagem por meio da ferramenta ‘regiões de interesse’ (ROI – *regions of interest*).

Devido à dificuldade em perceber como ocorre a discriminação dos dados no espaço multiespectral, foram testadas todas as funções de *kernel* disponíveis no ENVI bem como os parâmetros associados a cada uma, a fim de determinar qual função e parâmetros se adequou melhor aos dados e ao problema proposto. Os valores testados para o parâmetro de penalidade C foram: 1, 10, 100 e 200, e para o coeficiente γ foram utilizados: 0,1; 0,2; 0,5 e 0,9.

Como forma de avaliar cada configuração do SVM, foram utilizadas as amostras de treinamento para validar as classificações. O critério utilizado para selecionar o melhor resultado foi por meio do índice de concordância *Kappa*.

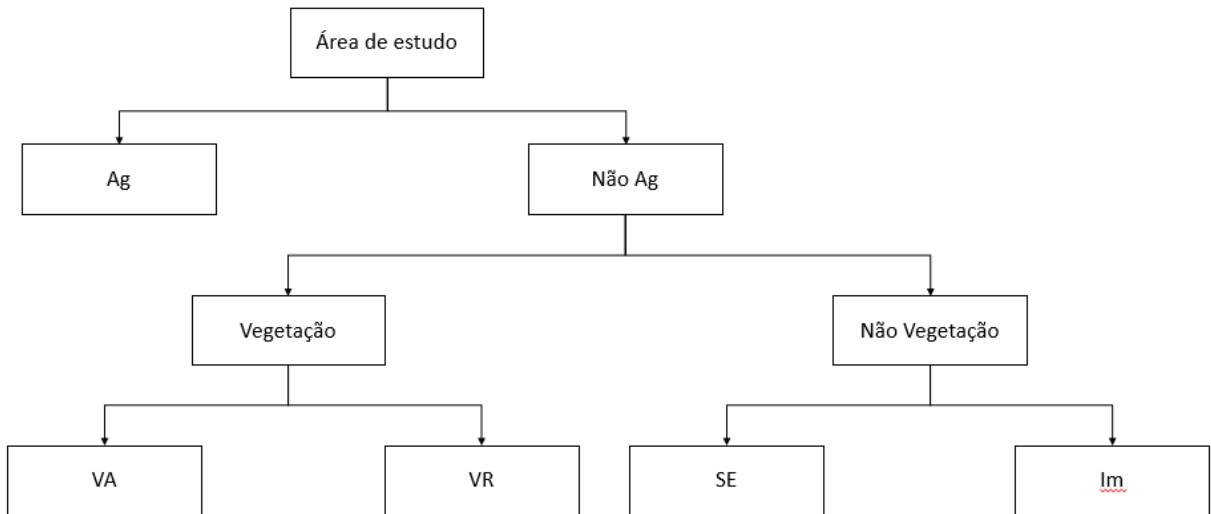
A configuração que melhor se adaptou ao conjunto de dados foi utilizando a função *kernel* de função de base radial, com coeficiente γ e parâmetro de penalidade C , respectivamente, iguais a 0,1 e 100.

A classificação orientada a objeto foi desenvolvida no software eCognition Developer 9² e partiu da delimitação prévia dos objetos na imagem por meio de uma segmentação multirresolução. Para tanto, foram avaliadas diversas configurações de parâmetros, com a finalidade de determinar aqueles que melhor se adequaram ao esquema de hierárquico proposto na Figura 17, no qual, inicialmente, objetos relacionados às superclasses água e não água foram identificados. No nível de classificação seguinte, faz-se a distinção entre áreas vegetadas e não vegetadas, finalizando com a discriminação entre os tipos de vegetação rasteira e arbórea, bem como entre áreas impermeáveis e solo exposto.

Para a aplicação de segmentação da imagem, foram realizados diversos testes na área de estudo para a definição dos parâmetros envolvidos no processo. A avaliação dos parâmetros se deu de forma visual, procurando-se evitar a criação de subobjetos e superobjetos para facilitar o processo. Sendo assim, foi usado apenas um nível para a discriminação dos objetos pertencentes ao sistema de classificação e definiu-se como adequados os seguintes valores de parâmetros de escala, de compacidade e de forma, respectivamente, iguais a 100; 0,5 e 0,5.

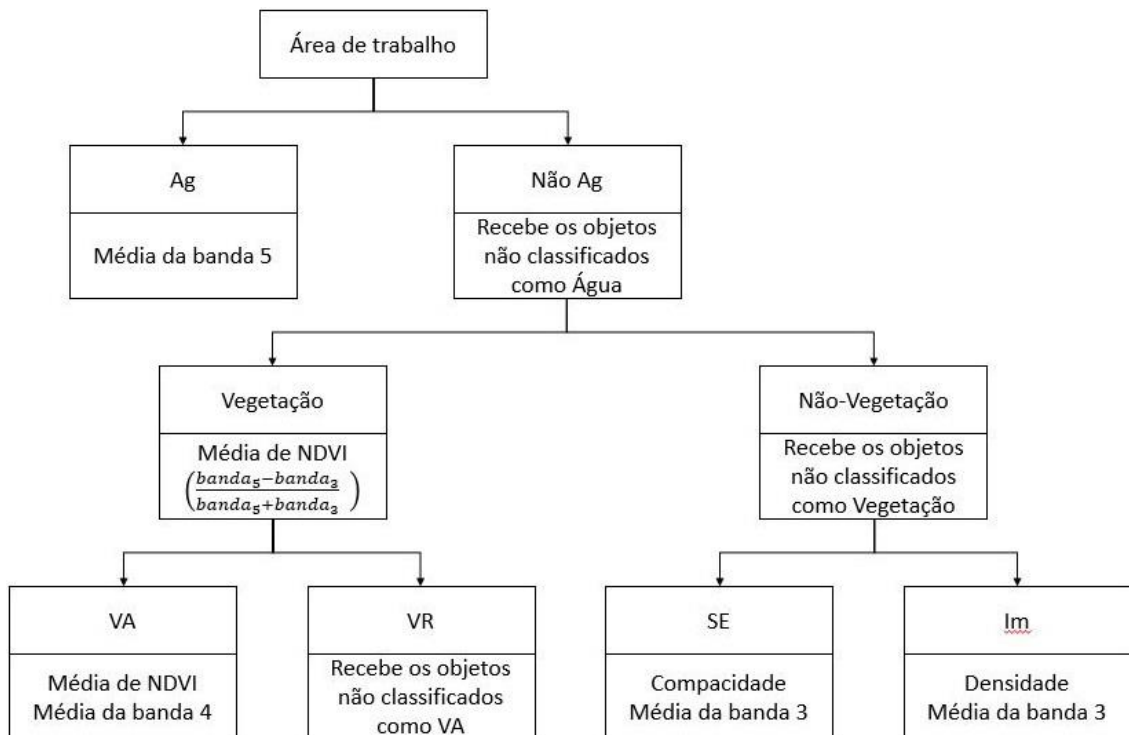
² Programa computacional produzido pela Trimble, voltado ao desenvolvimento da Análise de Imagens Orientada a Objeto

Figura 17 - Esquema de hierarquia de classes, em que *Ag* se refere a Água, *VA* é Vegetação Arbórea; *VR*, Vegetação Rasteira; *SE*, Solo Exposto e *Im* Impermeável.




A atribuição de classes aos objetos definidos na segmentação considerou características espectrais, de forma e/ou de localização. As regras utilizadas para a atribuição de classes aos objetos de imagem estão indicadas na Figura 18. Devido a diferença de iluminação entre as cenas, o limiar referente a cada classe é variável por imagem. Portanto, as regras de pertinência se mantiveram para todas as classes, mas os parâmetros variaram conforme as características da cena.

Figura 18 - Regras de pertinência de cada classe



O uso da banda 5 do RapidEye, posicionada na região espectral do infravermelho médio, para a discriminação dos objetos pertencentes a *Ag* se dá pela evidente diferença da energia eletromagnética refletida por corpos d'água em relação aos demais coberturas de terra, como pode ser visto na Figura 19.

Figura 19 - Comportamento espectral dos alvos água, vegetação e solo




Fonte: Adaptado de LILLESAND; KIEFER (1987)

O uso do índice de vegetação NDVI (*Normalized Difference Vegetation Index*) para a discriminação das coberturas vegetais se mostrou adequado pois, conforme Jensen (2007), esse índice realça as regiões de vegetação em relação às áreas de solo exposto e água. Já para a separação entre as classes *VA* e *VR*, além do NDVI, foi utilizada a banda 4, que é referente a região do vermelho limítrofe (690-730 nm), porque nesse intervalo de onda a energia refletida é mais sensível a características biofísicas das plantas, como a conteúdo de clorofila e índice de área foliar, e que são notavelmente diferentes entre vegetação rasteira e arbórea (KROSS *et al.*, 2015).

Observando as imagens utilizadas neste trabalho, notou-se que na banda do vermelho (Banda 3) os objetos pertencentes às classes *SE* e *Im* se destacavam em relação as demais. Contudo, telhados produzidos com cerâmica avermelhada e solos expostos possuem assinatura espectral similares nos comprimentos de onda variando de 400 a 1000 nm, como pode ser visto na Figura 20, por meio das curvas (2) e (6). Dessa forma, somente o uso da banda 3 não foi suficiente para a discriminação entre *SE* e *Im*, sendo necessário avaliar de

outras regras para separação entre essas classes. A solução encontrada foi a utilização da compacidade para *SE* e densidade para *Im*.

Figura 20 - Resposta espectral de diferentes elementos que compõem a paisagem urbana.



Fonte: HEROLD; ROBERTS (2010)

3.3.4 Análise das Transições nas Margens do reservatório Jaguari-Jacareí

Com a finalidade de investigar o que ocorreu nas margens do reservatório Jaguari-Jacareí a retração do corpo d'água devido à seca que culminou na crise hídrica de 2014, foram consideradas as classificações resultantes das duas datas. Para isso, foi criada uma máscara, a partir do delineamento da superfície aquática na imagem de 2013 (antes da seca) e avaliadas as mudanças nos tipos de cobertura da terra ocorridas no reservatório Jaguari-Jacareí no período entre 2013 e 2014, por meio de uma operação de intersecção espacial entre as imagens resultantes das classificações das cenas tomadas antes e após a seca, para cada uma das abordagens de classificação.

O resultado desse cruzamento, realizado a partir de ferramenta disponível no software Idrisi Selva 17.0³, é expresso na forma de mapas de transições espaço-temporais, representando as direções das mudanças ocorridas na área de entorno do reservatório Jaguari-Jacareí, de acordo com a seguinte indicação:

- *Ag* – Corpo d'Água não afetado pela seca, ou seja, áreas classificadas com água nas duas datas;
- *AgVA* – áreas de transição da classe Corpo d'Água para Vegetação Arbórea;
- *AgVR* – áreas de transição da classe Corpo d'Água para Vegetação Rasteira;
- *AgSE* – áreas de transição da classe Corpo d'Água para Solo Exposto; e
- *AgIm* – áreas de transição da classe Corpo d'Água para Área Impermeável.

3.3.5 Estimativa da Acurácia Temática

A acurácia temática da classificação de cada ano, 2013 e 2014, foi estimada por meio de informações derivadas da matriz de erro. A elaboração dessa matriz foi realizada no aplicativo Idrisi Selva 17.0⁴, tendo como referência imagens históricas disponibilizadas no GoogleEarthTM. Para isso, foi necessário realizar a interpretação visual das imagens de maior resolução espacial disponibilizadas no GoogleEarthTM para especificar a classe que se ajusta a cada amostra de referência.

Para estimar o tamanho da amostra foi utilizada a Equação 42, a partir da qual foram especificados dois grupos de dados de referência, um para 2013 e outro para 2014. Na definição do tipo de cobertura de cada ponto amostral foram utilizadas imagens históricas do GoogleEarthTM, considerando aquelas que mais se aproximavam das datas de aquisição do dado classificado.

A matriz de erro foi gerada pela verificação da concordância/discordância entre os elementos amostrais de referência e os respectivos elementos extraídos das classificações do mesmo ano. Com isso, foi possível estimar a acurácia global e por classe (acurácia do usuário e do produtor), além do índice de concordância *Kappa* para cada ano classificado, aplicando-se, respectivamente, as Equações 40, 41, 42 e 44. Além disso, foram utilizadas as estatísticas derivadas do valor de \hat{K} para cada matriz de erros, dados pelas Equações 45, 46 e 47.

³ Programa computacional produzido pela Clark Labs, voltado ao processamento e análise de imagens obtidas por Sensoriamento Remoto

3.3.6 Estimativa da Área da Classe Corpo d'Água

De acordo com Olofsson *et al.* (2014), a matriz de erro, além de possibilitar a análise de acurácia temática da classificação, pode servir como base para a estimação de área ocupada por uma dada classe k específica, entre as q classes de interesse. A estimativa de proporção da área ocupada pela classe k pode ser obtida por duas diferentes abordagens, ao recorrer às informações contidas na matriz de erro (Tabela 3, reescrita a partir da Tabela 1). A primeira possibilidade é utilizar a proporção de elementos amostrais presentes na matriz de erro e classificados como k ($p_{k*} = n_{k*}/N$). A alternativa é o uso da proporção de elementos amostrais referentes a classe k ($p_{*k} = n_{*k}/N$).

Tabela 3 – Matriz de erro de q classes

		Referência						Total
		A	B	...	k	...	q	
Classificação	A	n_{AA}	n_{AB}	...	n_{Ak}	...	n_{Aq}	n_{A*}
	B	n_{BA}	n_{BB}	...	n_{Bk}	...	n_{Bq}	n_{B*}
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	k	n_{kA}	n_{kB}	...	n_{kk}	...	n_{kq}	n_{k*}
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	Q	n_{qA}	n_{qB}	...	n_{qk}	...	n_{qq}	n_{q*}
Total		n_{*A}	n_{*B}	...	n_{*k}	...	n_{*q}	N

Fonte: Adaptado de OLOFSSON et al. (2014)

Os dois parâmetros tratados na estimação de área da classe k (p_{k*} e p_{*k}) provavelmente não apresentarão o mesmo valor e é necessário decidir qual das informações deve ser utilizada. O parâmetro p_{*k} é determinado a partir da referência de campo e, portanto, está sujeito a incertezas decorrentes da disposição espacial desse conjunto de dados. Por sua vez, p_{k*} é influenciado por erros de classificação, de modo que, a estimação de área a partir desse parâmetro é dependente da qualidade do produto analisado.

O parâmetro p_{*k} , como dito anteriormente, é influenciado pela disposição amostral da referência. Assim sendo, considerando as distribuições amostrais aleatória, estratificada e estratificada aleatória, sua influência na estimação de área pode ser minimizada por $\hat{p}_{ij} =$

$W_i \frac{n_{ij}}{n_{i*}}$ (OLOFSSON et al., 2014). Portanto, o parâmetro p_{*k} pode ser representado por um estimador pós-estratificado definido na Equação 45.

$$\hat{p}_{*k} = \sum_{i=1}^q W_i \frac{n_{ik}}{n_{i*}} \quad (49)$$

sendo:

\hat{p}_{*k} – estimador pós-estratificado da proporção de área ocupada por k ;

i – classe pertencente ao sistema de classificação, $i = A, B, \dots, k, \dots, q$;

W_i – proporção de área ocupada por i na imagem classificada, obtido diretamente pela análise do histograma da classificação;

n_{ik} – número de elementos amostrais na posição (i,k) da matriz de erro;

n_{i*} – número de elementos da referência pertencentes a classe i .

O estimador dado pela Equação 49 determina a proporção de área ocupada por k , que influencia na incerteza final dessa classe, assim como todas as demais classes que possuem certo grau de confusão com ela. De acordo com Stehman (2013), o uso do estimador pós-estratificado é a forma mais adequada de estimar a área ocupada por uma classe, quando se utiliza amostras de referência de campo na distribuição aleatória simples ou aleatória estratificada.

O desvio padrão do estimador estratificado é dado pela Equação 50.

$$S(\hat{p}_{*k}) = \sqrt{\sum_i W_i^2 \frac{\frac{n_{ik}}{n_{i*}} \left(1 - \frac{n_{ik}}{n_{i*}}\right)}{n_{i*} - 1}} = \sqrt{\sum_i \frac{W_i \hat{p}_{ik} - \hat{p}_{ik}^2}{n_{i*} - 1}} \quad (50)$$

Sendo assim, a área estimada para a classe k e sua incerteza são dadas, respectivamente, pelas Equações 51 e 52.

$$\hat{A}_k = A \times \hat{p}_{*k} \quad (51)$$

$$S(\hat{A}_k) = A \times S(\hat{p}_{*k}) \quad (52)$$

sendo:

- \hat{A}_k – número de pixels que definem a área estimada ocupada pela classe k ;
 A – número de pixels total, associados área total mapeada;
 $S(\hat{A}_k)$ – desvio padrão da área estimada de k .

O desvio padrão em área no terreno deve incorporar a área (Q) de cada *pixel* atribuído à classe k e é dado por:

$$S(\hat{A}_{k_{pixel}}) = \frac{S(\hat{A}_k)}{Q \times \hat{p}_{*k}} \quad (53)$$

em que $S(\hat{A}_{k_{pixel}})$ representa o desvio-padrão, em unidade de área, do *pixel* classificado como k .

3.3.7 Elaboração do Modelo Digital de Terreno

A representação tridimensional de dados posicionais, a partir de coordenadas geodésicas e altitude, é feita pelo MDT. Há duas formas de representar a topografia de uma região: grade regular ou rede irregular de triângulos ‘TIN’.

TIN é o método mais adequado para a representação de terrenos íngremes, uma vez que a qualidade do modelo gerado por grades regulares é dependente do espaçamento das grades. Nessa abordagem, são gerados triângulos, a partir de pontos que se interligam e interpoladas as altitudes nas posições intermediárias. No caso desse estudo, o TIN foi gerado a partir de dados obtidos por levantamento batimétrico e isolinhas derivadas do AW3D30.

Posteriormente, o TIN foi utilizado para a produção de um arquivo matricial, contendo a informação altimétrica da superfície, espaçada em uma malha regular de 5 metros, visando compatibilizar com a resolução espacial das imagens classificadas. Esse produto foi utilizado como base para a estimativa de volume do reservatório.

3.3.8 Estimativa de Volume do Reservatório


Os produtos gerados pelos classificadores SVM e OBIA foram utilizados como base para a estimativa de cota d’água e volume do reservatório. Para isso, foi utilizado o software

ArcGIS⁵, criando-se quatro camadas de informação poligonal, das quais cada uma representa uma delimitação do Jaguari-Jacareí obtida em cada data (2013 e 2014) e abordagem de classificação (SVM e baseada em objeto).

Para estimar as cotas de água do reservatório a partir dos polígonos gerados, utilizou-se os limites do reservatório e definiu-se um *buffer* de 5 metros em toda margem. Com isso, fez-se a extração dos parâmetros estatísticos média e desvio padrão que representam, respectivamente, a cota d'água e o erro dessa estimativa.

Para o cálculo de volume, utiliza-se a informação de profundidade, a qual é dada pela a diferença entre a altitude da superfície do espelho d'água e do fundo do reservatório. A Figura 21 representa as variações do relevo submerso do reservatório de Jaguari-Jacareí, para a cota de 833,51 metros.

Figura 21 - Representação do relevo submerso do reservatório Jaguari-Jacareí em 2013 (altitude ortométrica do espelho d'água em 833,51 metros).



⁵ Programa computacional produzido pela ESRI, voltado à produção e representação cartográfica e análise espacial.

A profundidade do reservatório foi representada em forma matricial, contendo g células. Assim sendo, a estimação de volume é expressa pelo produto entre a área de cada célula e o somatório da profundidade das g células arquivo matricial, conforme expresso na Equação 54.

$$\hat{V} = A_c \sum_{i=1}^g \Delta \hat{H}_i \quad (54)$$

Em que:

\hat{V} – volume estimado;

A_c – área de cada célula (25 metros),

$\Delta \hat{H}_i$ – profundidade estimada na célula i .

Como forma de analisar a acurácia da metodologia proposta para a estimativa de volume em relação ao volume oficial divulgado pela Sabesp, utilizou-se a diferença relativa entre os volumes divulgado e estimado (Equação 55).

$$Diferença\ Relativa\ (\%) = 100 * \frac{V_{estimado} - V_{Sabesp}}{V_{Sabesp}} \quad (55)$$

3.3.9 Propagação de Incerteza na Estimativa do Volume

A qualidade inerente de uma medida, obtida indiretamente por meio matemático, é dependente da propagação das incertezas das grandezas associadas à sua determinação, sendo essas observadas diretamente e com erros conhecidos (WOLF; GHILANI, 1997).

Segundo WOLF e GHILANI (1997), a variância de uma grandeza é determinada por um modelo matemático e expressa pela soma dos produtos entre as derivadas parciais ao quadrado e respectivos desvios padrão ao quadrado das variáveis envolvidas. Considerando que o erro na estimação do volume do reservatório inclui as estimativas de área e profundidade, deve-se propagar os erros envolvidos na definição dessas variáveis.

Tratando-se inicialmente da profundidade, considera-se que essa grandeza é expressa pela diferença entre a cota do espelho d'água e o fundo do reservatório (Equação 55).

$$\Delta\hat{H}_i = H_{Ag} - H_{fundo} \quad (56)$$

em que:

H_{Ag} – altitude ortométrica do espelho d'água

H_{fundo} – altitude ortométrica do fundo do reservatório

Portanto, aplicando a fórmula de propagação de erros, a incerteza da profundidade será expressa por:

$$\begin{aligned} \sigma_{\Delta\hat{H}_i}^2 &= \left(\frac{\partial(H_{Ag} - H_{fundo})}{\partial H_{Ag}} \right)^2 \sigma_{H_{Ag}}^2 + \left(\frac{\partial(H_{Ag} - H_{fundo})}{\partial H_{fundo}} \right)^2 \sigma_{H_{fundo}}^2 \\ \sigma_{\Delta\hat{H}_i}^2 &= \sigma_{H_{Ag}}^2 + \sigma_{H_{fundo}}^2 \rightarrow \sigma_{\Delta\hat{H}_i} = \sqrt{\sigma_{H_{Ag}}^2 + \sigma_{H_{fundo}}^2} \end{aligned} \quad (57)$$

Aplicando ao modelo matemático dado pela Equação 54 tem-se que a propagação de erros na estimação de volume é expressa pela Equação 58.

$$\begin{aligned} \sigma_{\hat{V}}^2 &= \left(\frac{\partial\hat{V}}{\partial\Delta\hat{H}_i} \sigma_{\Delta\hat{H}_i} \right)^2 + \left(\frac{\partial\hat{V}}{\partial A_{Ag}} \sigma_{A_{Ag}} \right)^2 \\ &= g A_c^2 \sigma_{\Delta\hat{H}_i}^2 + \sigma_{A_{Ag}}^2 \sum \Delta\hat{H}_i^2 \end{aligned} \quad (58)$$

em que:

$\frac{\partial\hat{V}}{\partial\hat{h}}$ – derivada parcial do volume em relação a profundidade estimada

$\sigma_{\Delta\hat{H}_i}$ – desvio padrão médio da profundidade estimada, considera-se o mesmo valor para todas as células

$\frac{\partial\hat{V}}{\partial A_c}$ – derivada parcial do volume em relação a área da célula

$\sigma_{A_{Ag}}$ – desvio padrão da área da célula, considera-se o mesmo valor para todas as células

g – total de células que compõem o reservatório.

Portanto, a acurácia da estimação de volume, Equação 59, é determinada aplicando-se raiz quadrada à Equação 58.

$$Acurácia = \sigma_{\hat{v}} = \sqrt{\sigma_{\hat{v}}^2} \quad (59)$$

4 RESULTADOS E DISCUSSÃO

4.1 Acurácia Temática das Classificações

Com a finalidade validar o resultado das classificações, por meio da acurácia temática das informações extraídas, foi construída uma matriz de erro para cada classificação indicando o grau de correspondência de cada uma com os dados de referência. O tamanho da amostra usado para análise da acurácia temática das classificações foi estabelecido conforme a Equação 42, considerando a precisão desejada (β) de 95% e nível de significância (α) igual a 5% foi estabelecido em 662 pontos amostrais. Os elementos amostrais foram distribuídos de forma estratificada aleatória e a referência quanto ao verdadeiro tipo de cobertura da terra foi definida por meio da interpretação de imagens históricas do GoogleEarth™, selecionando-se aquelas que mais se aproximavam das datas de tomada dos dados em 2013 e 2014. As matrizes de erros obtidas pela confrontação dos dados de referência com o resultado das classificações são apresentadas na Tabela 4, referente à classificação OBIA aplicada à imagem de 2013; Tabela 5, referente à classificação SVM aplicada à imagem de 2013; Tabela 6, referente à classificação OBIA aplicada à imagem de 2014 e Tabela 9, referente à classificação SVM aplicada à imagem de 2014.

Tabela 4 - Matriz de erro referente à classificação OBIA aplicada à imagem RapidEye tomada em 2013

		Referência					Total
		Ag	VA	VR	SE	Im	
Classificação	Ag	90	0	0	0	0	90
	VA	0	193	7	0	1	201
	VR	0	22	219	20	14	275
	SE	0	0	8	47	9	64
	Im	1	0	4	11	16	32
	Total	91	215	238	78	40	662

Tabela 5 - Matriz de erro referente à classificação SVM aplicada a imagem RapidEye tomada em 2013

		Referência					
		Ag	VA	VR	SE	Im	Total
Classificação	Ag	90	0	0	0	0	90
	VA	0	207	6	0	0	213
	VR	0	6	207	11	3	227
	SE	1	2	25	57	24	109
	Im	0	0	0	10	13	23
	Total	91	215	238	78	40	662

Tabela 6 - Matriz de erro referente à classificação OBIA aplicada a imagem RapidEye tomada em 2014

		Referência					
		Ag	VA	VR	SE	Im	Total
Classificação	Ag	49	0	0	1	0	50
	VA	0	230	18	0	0	248
	VR	0	10	216	11	10	247
	SE	1	0	6	67	6	80
	Im	0	0	5	15	17	37
	Total	50	240	245	94	33	662

Tabela 7 - Matriz de erro referente à classificação SVM aplicada a imagem RapidEye tomada em 2014

		Referência					
		Ag	VA	VR	SE	Im	Total
Classificação	Ag	50	0	0	1	0	51
	VA	0	238	17	1	0	256
	VR	0	2	220	5	2	229
	SE	0	0	6	81	13	100
	Im	0	0	2	6	18	26
	Total	50	240	245	94	33	662

Pelas Tabelas 6 a 9, verifica-se que a classe Área Impermeável (Im) foi aquela que mais se confundiu com as demais, principalmente com Solo Exposto (SE), em ambas as abordagens de classificação e, em menor grau, com Vegetação Rasteira (VR), no método OBIA. De acordo com Herold e Roberts (2010), telhados cerâmicos de material avermelhado apresentam resposta espectral semelhante ao de solo exposto, principalmente nos

comprimentos de onda desde o verde até o infravermelho próximo (400nm~1000nm), conforme indicado na Figura 20, na qual as curvas espectrais de telhado cerâmico avermelhado (curva 2) e solo exposto (curva 6) apresentam resposta espectral similar.

Em menor grau, também foi observada confusão entre as classes SE (Solo Exposto) e VR (Vegetação Rasteira), e VA (Vegetação Arbórea) com VR. O primeiro caso pode ser atribuído ao efeito de mistura espectral, em que cada pixel pode conter mais de uma classe na sua dimensão espacial (SCHOWENGERDT, 2007), incorrendo em divergências entre a classificação de um *pixel* e a sua referência. Por outro lado, além da questão da mistura espectral, no segundo caso, as curvas de resposta espectral entre espécies de vegetação possuem características similares, definindo, em algumas condições fenológicas e morfológicas, confusão na discriminação das espécies de vegetação (NOVO, 2008).

Nas matrizes de erro das classificações, Tabelas 6 a 9, percebe-se que a classe Ag (Corpo d'Água) apresenta pouca confusão com as demais devido à assinatura espectral bastante particular (Figura 19). Portanto, a extração de corpos d'água a partir de classificação de imagens multiespectrais nas bandas do infravermelho é realizada, praticamente, na sua íntegra.

Os indicadores globais da acurácia da classificação foram obtidos por meio das Equações 39, 40, 41 e 43, as quais produziram, respectivamente, as informações sobre acurácia global, acurácia do usuário, acurácia do produtor e índice de concordância *Kappa*, apresentadas na Tabela 8, para a classificação OBIA e Tabela 9, para a classificação SVM. Em ambas as tabelas, esses indicadores são fornecidos para a classificação das cenas tomadas em 2013 e 2014.

Tabela 8 – Acurácia global, acurácia de usuário, acurácia de produtor e Índice de Concordância *Kappa* para as classificações realizadas a partir da abordagem OBIA

Classe	2013		2014	
	Usuário (%)	Produtor (%)	Usuário (%)	Produtor (%)
Ag	98,90	100,00	98,00	98,00
VA	89,77	96,02	95,83	92,74
VR	92,02	79,64	88,16	87,45
SE	60,26	73,44	71,28	83,75
Im	40,00	50,00	51,52	45,95
Global (%)	85,35		87,46	
Kappa	0,80		0,82	

Tabela 9 – Acurácia global, acurácia de usuário, acurácia de produtor e Índice de Concordância *Kappa* para as classificações realizadas a partir da abordagem SVM

Classe	2013		2014	
	Usuário (%)	Produtor (%)	Usuário (%)	Produtor (%)
Ag	98,90	100,00	100,00	98,04
VA	96,28	97,18	99,17	92,97
VR	86,97	91,19	89,80	96,07
SE	73,08	52,29	86,17	81,00
Im	32,50	56,52	54,55	69,23
Global (%)	86,71		91,69	
Kappa	0,82		0,88	

A partir das Tabela 8 e Tabela 9, nota-se que em todas as classificações, as classes *Im* e *SE* apresentaram as menores acurácias, seja de usuário como de produtor. De fato, a ocorrência desse fato está relacionada, principalmente, com a confusão decorrente da similaridade nas assinaturas espectrais de telhado de cerâmico avermelhado e áreas de solo exposto, nos comprimentos de onda do visível e início do infravermelho próximo. Já as demais classes apresentaram acurácia de usuário e de produtor acima de 75% em todas as classificações, demonstrando que estas informações foram produzidas com boa qualidade e estão adequadas para se utilizar às mais variadas atividades em que possam ser empregadas.

Com os resultados mostrados nas Tabela 8 e Tabela 9 percebe-se, ainda, a superioridade no desempenho, alcançado pela abordagem SVM em relação à OBIA. Além disso, os valores de acurácia do usuário e do produtor obtidos com esse método, o SVM, foram superiores para praticamente todas as classes. Devido a isso, as acurácias globais e índice de concordância *Kappa* das classificações SVM também foram superiores aos seus correlatos obtidos por OBIA. Enquanto a acurácia global representa a proporção de elementos amostrais que foram corretamente classificadas, o índice *Kappa* é baseado na diferença da concordância real, obtida pela diagonal principal da matriz de erro, e a concordância ao acaso, dada pela linha e coluna de total na matriz de erro e, com isso, é tido como um estimador de qualidade mais rigoroso (CONGALTON; GREEN, 1999). O valor de *Kappa* possui diversas interpretações, sendo uma delas expressa no Quadro 5, o qual mostra que as classificações obtiveram concordância quase perfeita com a referência de campo, exceto a OBIA com imagem de 2013, que apresentou excelente concordância.

Quadro 5 - Interpretação do Índice de Concordância *Kappa*

Coeficiente Kappa	Concordância
< 0,41	Pobre
0,41 – 0,60	Moderada
0,61 – 0,75	Boa
0,76 – 0,80	Excelente
> 0,8	Quase Perfeita

Fonte: Adaptado de RICHARDS (2013)

Utilizou-se a Equação 45 para o cálculo da variância de \hat{K} referente à matriz de erro de cada classificação. Os resultados obtidos estão dispostos na Tabela 10.

Tabela 10 – Variância de \hat{K} calculadas a partir das abordagens de classificação: OBIA e SVM aplicadas às imagens RapidEye tomadas em 2013 (OBIA13; SVM13) e 2014 (OBIA14; SVM14)

$v\hat{a}r(\hat{K}_{OBIA13})$	$v\hat{a}r(\hat{K}_{SVM13})$	$v\hat{a}r(\hat{K}_{OBIA14})$	$v\hat{a}r(\hat{K}_{SVM14})$
0,000353	0,000308	0,000326	0,000227

Conforme mostra a Tabela 10, as variâncias obtidas para cada valor de \hat{K} são relativamente similares, exceto no caso da classificação SVM de 2014, a qual apresentou variância cerca de 30% inferior às demais.

Finalmente, foram aplicados testes estatísticos para avaliar a significância das classificações resultantes, a partir dos valores de \hat{K} estimado. Em um primeiro momento, foi verificado se existe concordância entre cada uma das classificações SVM e OBIA com os dados de treinamento adquiridos para as respectivas datas (2013 e 2014), por meio da Equação 46. Os resultados obtidos podem ser vistos na Tabela 11.

Tabela 11 – Valores do teste Z para as classificações OBIA e SVM, para os anos de 2013 e 2014

Z_{OBIA13}	Z_{SVM13}	Z_{OBIA14}	Z_{SVM14}
42,37	46,61	45,47	58,54

Considerando que as classificações foram analisadas a um nível de confiança de 95%, definindo-se um valor de Z-tabelado igual a 1,96, verifica-se que Z calculado foi superior a esse valor para todas as classificações. Com isso, pode se assumir que, os dados de treinamento utilizados resultaram em classificações significativas.

Em um segundo momento foi avaliado se as classificações possuem desempenho similar, utilizando a Equação 47, a qual compara as matrizes de erro resultantes de duas classificações. Na Tabela 12 apresentam-se os valores de Z calculado, resultado da comparação entre pares de classificação, assumindo nível de confiança de 95%.

Tabela 12 – Teste Z para verificar a similaridade entre pares de classificações

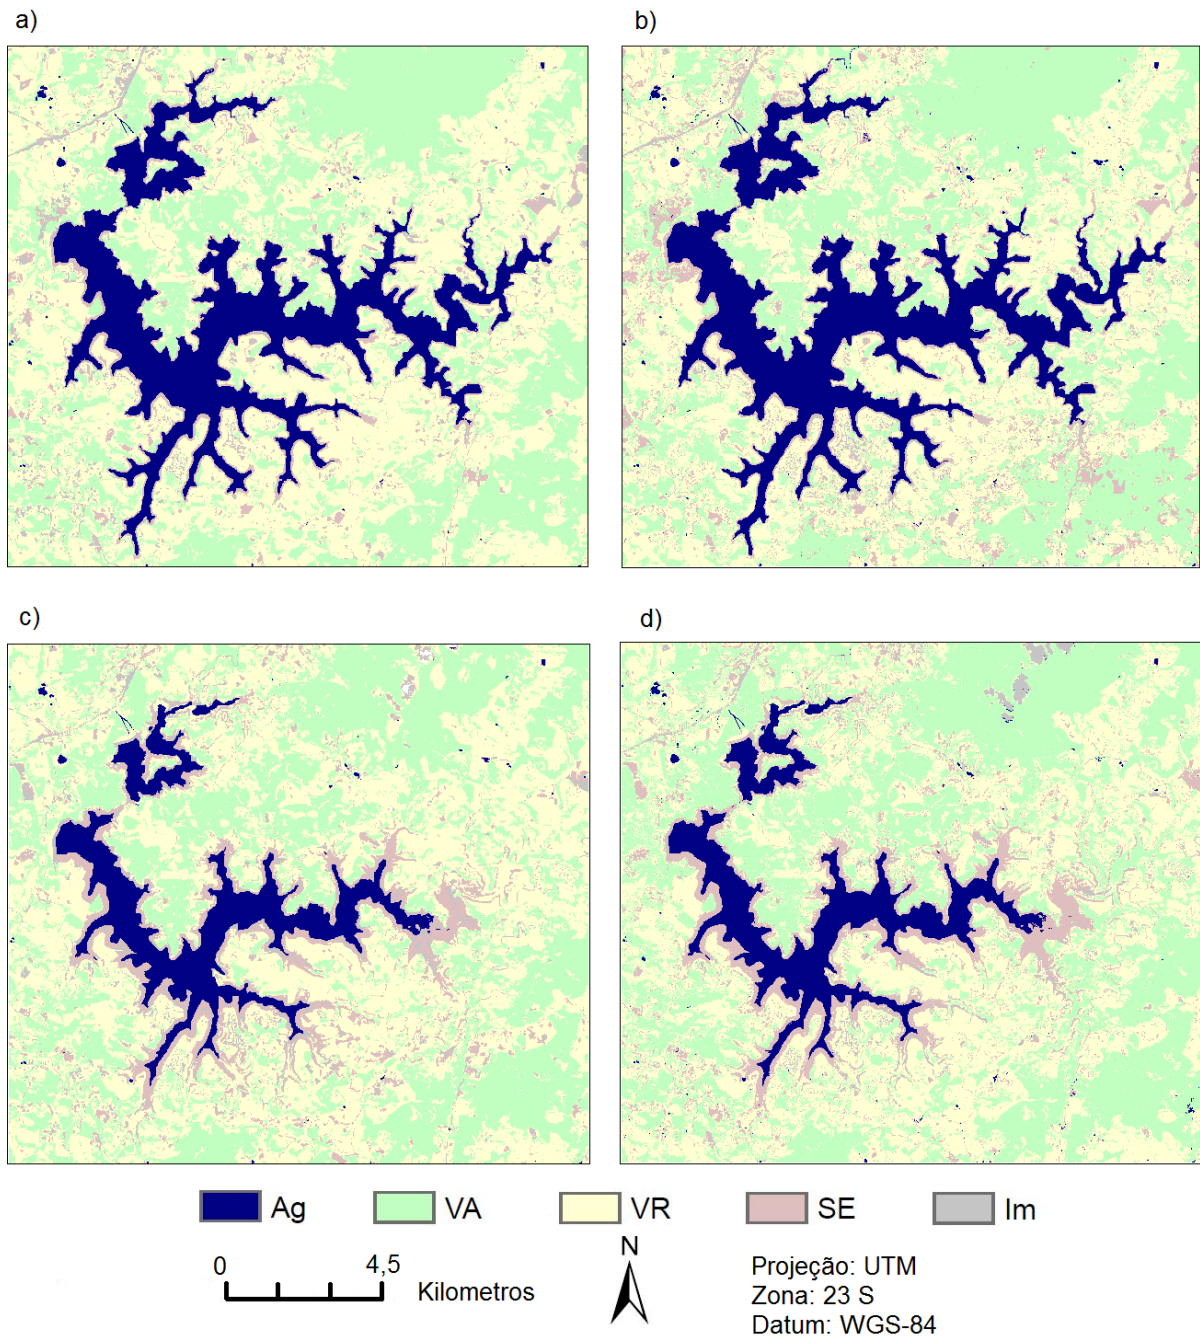
	OBIA13	SVM13	OBIA14	SVM14
OBIA13				
SVM13	0,86			
OBIA14	0,96	0,12		
SVM14	3,57	2,77	2,59	

Assumindo que a similaridade deve atender a um nível de confiança de 95%, portanto, os pares de classificação que apresentarem valores inferiores a 1,96 na Tabela 12, podem ser considerados estatisticamente similares. Como pode ser observado, todas as classificações podem ser consideradas estatisticamente similares para esse nível de confiança, com exceção da SVM de 2014. Essa última, por ser estatisticamente diferente das demais e apresentar valor de Z individual superior, teve um desempenho estatisticamente superior aos demais.

4.2 Imagens Classificadas para 2013 e 2014 por SVM e OBIA

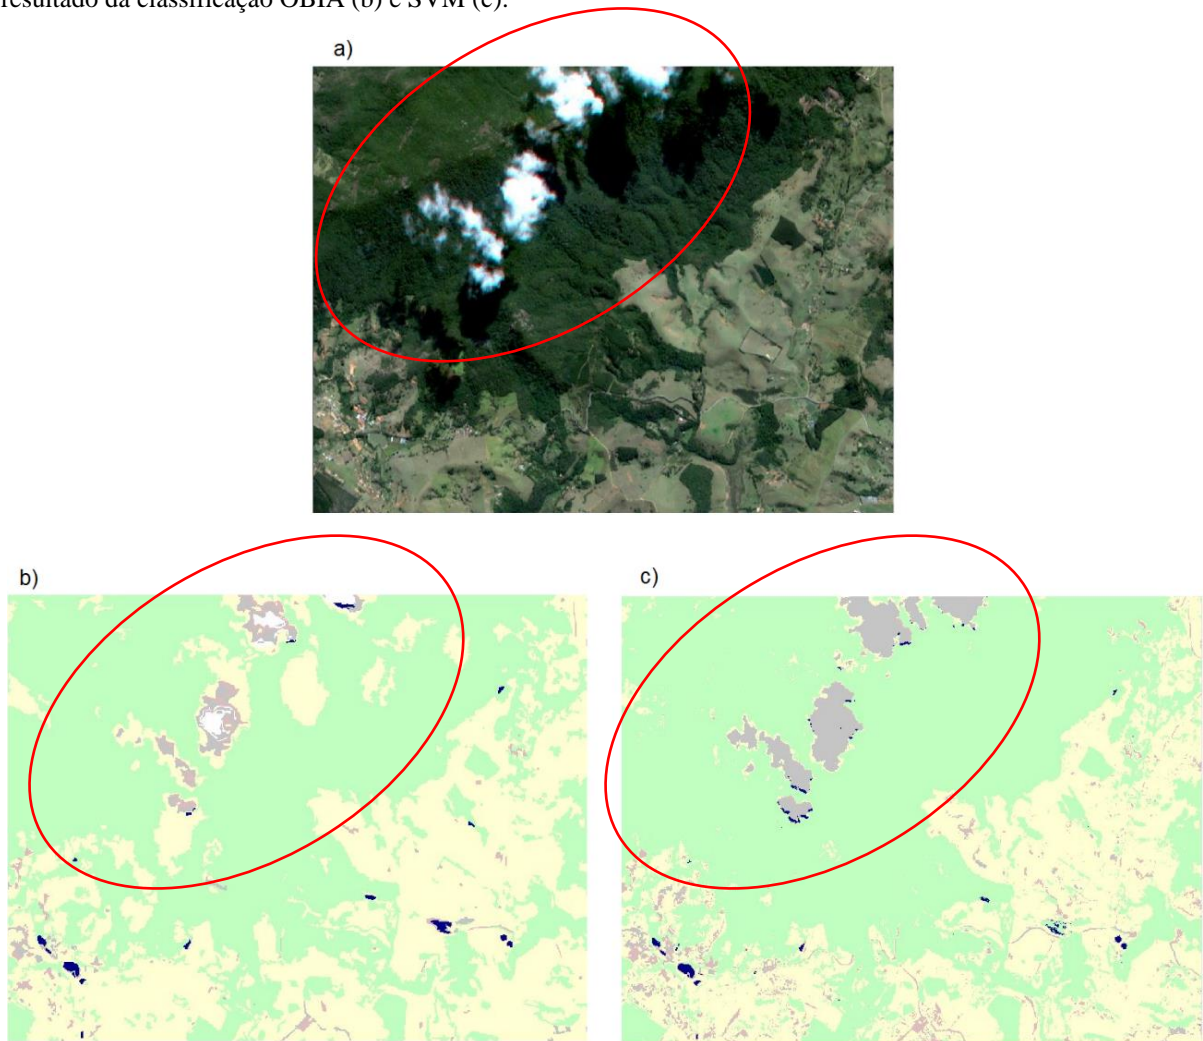
Os resultados das classificações das imagens RapidEye, submetidas aos pré-processamentos especificados no item 3.2.1 da metodologia, são apresentadas nas imagens da Figura 22, na qual estão indicados os resultados obtidos a partir da abordagem orientada a objeto (OBIA) aplicada as imagens tomadas em 2013 (a) e 2014 (c) e baseada em *pixel* (SVM) das cenas de 2013 (b) e 2014 (d). A denominação das classes expressas na legenda dessa figura representa: Ag – Corpo d'Água, VA – Vegetação Arbórea, VR – Vegetação Rasteira, SE – Solo Exposto e Im – Área Impermeável.

Figura 22 - Classificações das imagens RapidEye da área de estudos, abrangendo o entorno do reservatório Jaguari-Jacareí. Imagens tomadas em 2013 classificadas pelo método OBIA (a) e SVM (b); imagens de 2014 resultantes da aplicação das abordagens OBIA (c) e SVM (d).



O cenário apresentado na Figura 23 ilustra as diferenças nos resultados dessas abordagens de classificação. Uma das imagens que compõem a cena do ano de 2014, apresenta uma área coberta por nuvem, como visto na Figura 23a.

Figura 23 - Recorte da cena de 2014 da área de estudos indicando uma local com cobertura de nuvens (a) e o resultado da classificação OBIA (b) e SVM (c).



Os classificadores produziram informações bem distintas para essa área. Na OBIA (Figura 23b), as nuvens foram classificadas como sendo, majoritariamente, *VR*; seguido pelas classes *Im* e *SE*, e ainda houve objetos que não foram atribuídos a qualquer classe. Por outro lado, na classificação SVM (Figura 23c) os *pixels* de nuvem e sombras de nuvens foram atribuídos, na maior parte a classe *Im*, e em menor proporção a *VR* e *Ag*. Além disso, nota-se que na abordagem por SVM, as sombras das nuvens foram, em sua maioria classificadas como *VA*, demonstrando o potencial do classificador em produzir informação acurada mesmo em circunstâncias adversas.

A fim de avaliar o número e a proporção de *pixels* atribuídos a cada classe de cobertura de terra, foram utilizados os histogramas das classificações para a verificar a frequência de ocorrência de cada classe na área de estudo. A Tabela 13 mostra os resultados

obtidos com abordagem OBIA, enquanto que a Tabela 14 representa os valores alcançados utilizando SVM.

Tabela 13 - Número e proporção de *pixels* atribuídos a cada classe nos anos de 2013 e 2014, a partir do método OBIA

Classe	2013		2014	
	Número de <i>pixels</i>	Proporção de <i>pixels</i> (%)	Número de <i>pixels</i>	Proporção de <i>pixels</i> (%)
0	1 708	0,0002	6 252	0,0007
Ag	1 407 004	0,1460	704 841	0,0731
VA	3 032 304	0,3146	3 472 838	0,3604
VR	4 390 636	0,4556	4 342 911	0,4506
SE	552 634	0,0573	790 624	0,0820
Im	253 034	0,0263	319 854	0,0332

Tabela 14 – Número e proporção de *pixels* atribuídos a cada classe nos anos de 2013 e 2014, a partir do método SVM

Classe	2013		2014	
	Número de <i>pixels</i>	Proporção de <i>pixels</i> (%)	Número de <i>pixels</i>	Proporção de <i>pixels</i> (%)
Ag	1 441 499	0,1496	712 531	0,0739
VA	3 269 592	0,3393	3 806 438	0,3950
VR	3 892 055	0,4038	3 944 829	0,4093
SE	891 380	0,0925	950 217	0,0986
Im	142 794	0,0148	223 305	0,0232

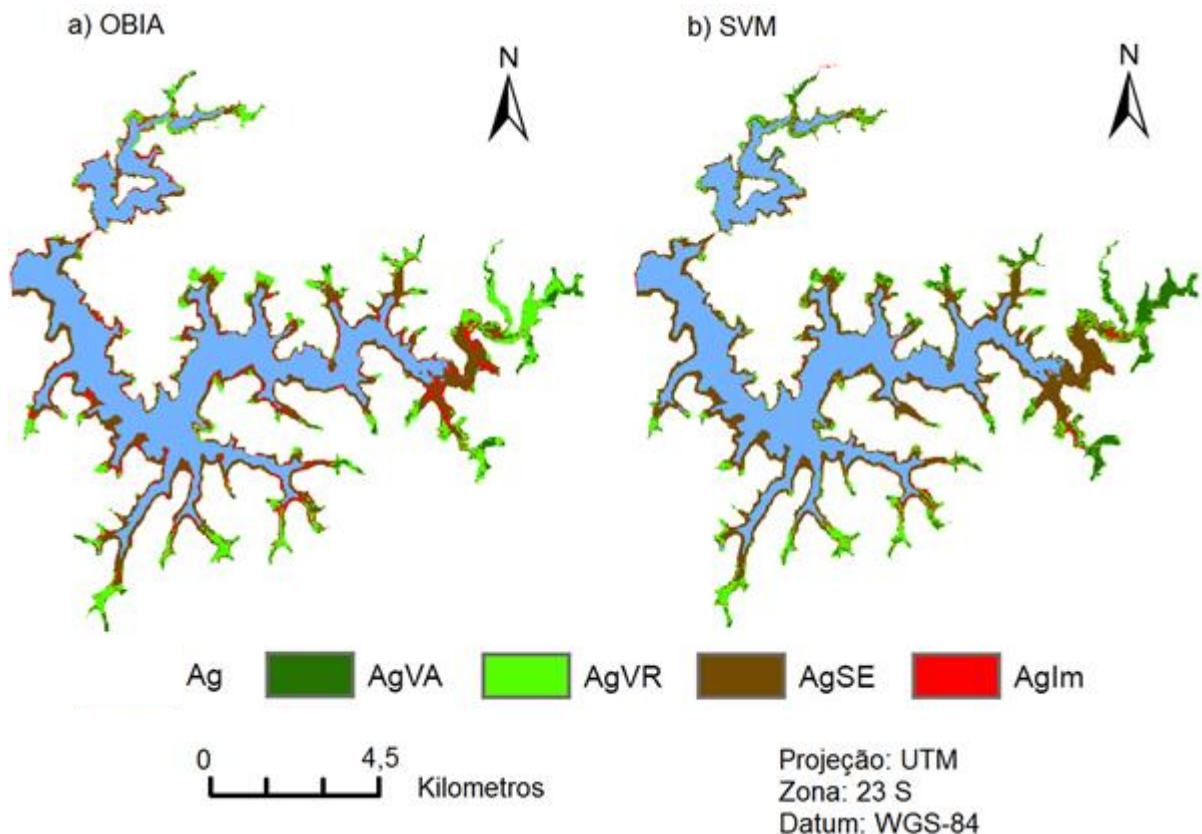
Nota-se na classificação OBIA (Tabela 13) que houve aumento de 4544 *pixels* entre 2013 e 2014, que não receberam atribuição de qualquer classe. Tal fato pode ser explicado pela presença de nuvens na cena do ano de 2014, conforme visto na Figura 23. Por outro lado, a classificação com o método SVM pode levar a conclusão errônea de que houve expansão de área de cobertura impermeável de, aproximadamente, 79% ao aplicar a razão entre as quantidades de *pixels* dos anos de 2014 e 2013, presentes na Tabela 14. Entretanto, as nuvens presentes na imagem foram, majoritariamente, atribuídas a classe *Im* na classificação SVM.

Comparando as Tabelas 4 e 5, nota-se que a abordagem OBIA foi capaz de extrair áreas maiores das classes *VR* e *Im*, em ambos os anos. Enquanto que os *pixels* associados às classes *Ag*, *VA* e *SE* foram em número maior ao aplicar a classificação SVM.

4.3 Transições na Cobertura da Terra nas Margens do Reservatório Jaguari-Jacareí

Os mapas de transição entre os tipos de uso e cobertura da terra, definidos especialmente nas margens do reservatório Jaguari-Jacareí, resultantes dos cruzamentos entre as classificações de 2013 e 2014 são apresentados na Figura 24, para cada método de classificação: OBIA (a) e SVM (b). Em ambas as classificações, as classes de transição foram denominadas: *Ag* (corpo d'água que se manteve inalterado), *AgVA* (transição de água para vegetação arbórea), *AgVR* (transição de água para vegetação rasteira), *AgSE* (transição de água para solo exposto) e *AgIm* (transição de água para área impermeável).

Figura 24 – Mapa de mudanças ocorridas nos tipos de cobertura da terra do entorno do reservatório Jaguari-Jacareí, entre os anos de 2013 e 2014, obtidas pelas classificações: OBIA (a); SVM (b).



Observando a Figura 24a, nota-se que foi detectada uma área considerável como transição entre Água e área Impermeável (*AgIm*). Entretanto, na área inundada do reservatório, as únicas coberturas impermeáveis são as instalações da represa, píeres e o afloramento rochoso do canal que interliga os rios Jaguari e Jacareí. A detecção excessiva dessa classe pode estar relacionada à confusão na discriminação entre as classes *SE* e *Im*. Essa

última classe foi, aproximadamente, 43,24% maior na abordagem por OBIA do que na SVM, para a classificação da cena de 2014.

Por outro lado, no mapa de mudanças obtido pela abordagem SVM (Figura 24b), ocorreu uma área considerável associada à transição da classe Corpo d'Água para Vegetação Arbórea. De fato, em alguns locais nas margens do reservatório, pode-se notar a alternância de água para arbustos, como pode ser visualizado em destaque na Figura 25. A atribuição dessas áreas à VA pode estar relacionada às características de intensidade da cor e textura da vegetação arbustiva, que parece estar mais próxima de vegetação arbórea do que da rasteira.

Figura 25 - Recorte de uma das áreas do reservatório Jaguari-Jacareí onde houveram mudança de água para arbusto. a) Imagem adquirida em 2012; Imagem adquirida em 2015



Fonte: Google

Com a finalidade de realizar análises quantitativas, utilizou-se os histogramas de frequência das mudanças ocorridas nas margens do reservatório (Figura 24). Os valores obtidos se encontram dispostos na Tabela 15.

Tabela 15 - Número e proporção de *pixels* presentes no mapa de detecção de mudanças do reservatório

Classe de transição	OBIA		SVM	
	Número de <i>pixels</i>	Proporção (%)	Número de <i>pixels</i>	Proporção (%)
<i>AgVA</i>	39 597	2,84	98 057	6,90
<i>AgVR</i>	209 118	14,98	159 382	11,21
<i>AgSE</i>	355 028	25,44	443 789	31,21
<i>AgIm</i>	98 279	7,04	26 105	1,84

Diante do exposto na Tabela 15, é perceptível a diferença na ocorrência das transições nas *AgVA* e *AgSE* para os dois métodos de classificação, embora tenham sido mais

frequentes na abordagem SVM. As discrepâncias foram, respectivamente, de 58460 e 88761 *pixels*.

Em contrapartida, as classes de transição *AgVR* e *AgIm* ocorreram com maior frequência na classificação resultante da abordagem orientada a objetos, cujas as discrepâncias representam, nessa ordem, 49736 e 72174 *pixels*. A maior presença de *AgIm* está associada à confusão entre *Im* e *SE* observada na classificação OBIA.

De acordo com os valores apresentados na Tabela 15, aproximadamente, a metade da área do espelho d'água do reservatório em 2013 se manteve em 2014, considerando os resultados obtidos por ambos classificadores. Na abordagem SVM, a área do corpo d'água que se manteve como tal foi ligeiramente maior que na OBIA, apresentando discrepância de 1120 *pixels*. A similaridade nos valores obtidos se deve ao comportamento espectral distinto da água em relação às demais classes. Com isso, a extração de corpos d'água é realizada de forma efetiva por ambos os classificadores.

4.4 Área do Corpo d'Água em 2013 e 2014

A estimação de área ocupada pela classe Corpos d'Água em 2013 e 2014 foi realizada por meio do estimador estratificado (Equação 45) e da Equação 47, nas quais são utilizadas informações contidas nas matrizes de erro das classificações (Tabelas 6 a 9) e as proporções de *pixels* classificados como cada classe (Tabela 13 e Tabela 14). Os resultados obtidos são mostrados na Tabela 16.

Tabela 16 – Proporção da área de estudo ocupada pelo Corpo d'Água, estimada a partir de cada abordagem de classificação, nos anos de 2013 e 2014.

ANO	CLASSIFICAÇÃO	\hat{p}_{+Ag}	\hat{A}_{Ag} (KM ²)
2013	OBIA	0,15	35,37
	SVM	0,15	36,24
2014	OBIA	0,07	17,52
	SVM	0,07	17,46

Conforme mostra a Tabela 13, a área estimada ocupada pela classe Corpo d'Água foi maior na abordagem SVM, em 2013, apresentando discrepância de 0,8691 km² em relação a OBIA. Contudo, o inverso ocorreu para o ano de 2014, quando a área estimada pelo método OBIA foi superior em 0,0517 km². Essa superioridade em área estimada não era esperada,

visto que, conforme Tabela 13 e Tabela 14, a quantidade *pixels* atribuídos à *Ag* foi inferior nessa abordagem. Pelo fato da Equação 45 estimar a proporção da área ocupada por classe a partir da confusão dessa classe com as demais verifica-se, pelos valores expressos nas matrizes de erro (Tabela 6 e Tabela 7), que a abordagem OBIA apresentou dois casos de confusão entre amostras de *Ag* e *SE*, enquanto que a SVM somente um. Portanto, a superioridade de área estimada pela orientação a objeto, neste caso, pode estar associada à essa confusão ocorrida entre *Ag* e *SE*.

Os desvios-padrão do estimador estratificado (Equação 46), da área estimada (Equação 48) e do *pixel* (Equação 49), para cada classificação abordagem de classificação e data de aquisição da imagem, estão dispostos na Tabela 17.

Tabela 17 - Desvios-padrão do estimador estratificado, da estimação de área da classe Corpo d'Água (*Ag*) e do *pixel* pertencente a *Ag* (valores relativos a 1σ de confiança)

ANO	CLASSIFICAÇÃO	$S(\hat{p}_{*k}) (10^{-3})$	$S(\hat{A}_{Ag}) (KM^2)$	$S(\hat{A}_{Ag_{pixel}}) (DM^2)$
2013	OBIA	0,82	0,20	13,97
	SVM	0,85	0,20	14,10
2014	OBIA	1,79	0,43	61,43
	SVM	1,45	0,35	50,00

Em decorrência da seca que culminou com a crise hídrica, houve redução na área ocupada pela classe Corpo d'Água em 2014 e uma vez que o estimador estratificado é sensível ao tamanho da amostra da classe de interesse, *Ag*, já que o erro apresenta maior influência nos menores conjuntos de referência, as classificações das imagens de 2013 foram mais confiáveis para a estimativa de área, conforme pode ser visto pelos desvios-padrão indicados na Tabela 17.


Os desvios-padrão obtidos para os métodos OBIA e SVM se mostraram similares para a classificação de 2013 e ambas apresentaram somente um caso de confusão de *Ag* com outra classe. Contudo, pelos resultados obtidos para 2014, fica evidente o maior potencial da abordagem SVM para estimação de área ocupada por corpos d'água na região de estudo.

4.5 MDT e Cota d'Água estimada em 2013 e 2015

O segundo componente especificado para a estimação do volume foi a cota do reservatório quando da tomada das imagens em 2013 e 2014. Para a estimativa do nível da

água foi necessário produzir o MDT, representando o relevo submerso do reservatório, a partir dos dados batimétricos disponibilizados pela Sabesp, complementados pelas isolinhas do modelo AW3D30 (Figura 26).

Figura 26 - MDT do reservatório Jaguari-Jacareí, produzido a partir de dados obtidos por batimetria e do modelo AW3D30.



O nível de água foi, então, estimado a partir do valor resultante da intersecção entre a superfície delimitada nas classificações do reservatório e o MDT produzido com dados obtidos por batimetria e do modelo AW3D30. As cotas de inundação estimadas e respectivos desvios-padrão estão indicados na Tabela 18, juntamente com as cotas d'água divulgadas pela Sabesp.

Tabela 18 – Cota d'água estimada a partir das superfícies aquáticas definidas nas classificações do reservatório e respectivos desvios-padrão. Na última linha estão indicadas as cotas divulgadas pela Sabesp.

Classificação	2013		2014	
	Cota d'água (m)	σ_{cota} (m)	Cota d'água (m)	σ_{cota} (m)
OBIA	833,33	3,49	817,49	2,18
SVM	833,96	3,75	817,54	2,21
Sabesp	833,51 m		817,26 m	

Para efeito de comparação, foram considerados os valores de cota da água disponibilizados pela Sabesp para as datas de tomada das imagens RapidEye (9 de setembro de 2013 e 30 de julho de 2014), os quais foram, respectivamente, 833,51 e 817,26 metros.

Como pode ser visto na Tabela 18, apesar do método utilizado para estimativa das cotas d'água resultar em valores razoavelmente próximos daqueles divulgados pela Sabesp, as grandezas obtidas têm desvios-padrão elevados. A causa disso pode estar associada à incerteza no georreferenciamento das imagens e/ou à própria delimitação do reservatório a partir de imagens RapidEye. No primeiro caso, pode existir deslocamento de posicionamento entre as imagens RapidEye, os pontos de levantamento batimétrico e o AW3D30. Com isso, a incerteza da posição das fontes de dados é propagada na estimação da cota. Por outro lado, a extração do reservatório a partir de imagens RapidEye, cuja resolução espacial é 5 metros, pode ser considerada grosseira para a finalidade de estimar a cota d'água.

Pelo fato das estimações das cotas para o ano de 2013 incluírem a região do MDT gerado a partir de dados AW3D30, com precisão muito menor que as medidas batimétricas, os desvios-padrão para esse ano são maiores do que para o ano de 2014, no qual o nível da água foi estimado somente por meio de dados oriundos do levantamento batimétrico.

Conforme mostram os resultados expostos na Tabela 18, as cotas estimadas a partir das delimitações pela abordagem OBIA foram aquelas que mais se aproximaram dos valores divulgados pela Sabesp, apresentando, inclusive, menores desvios-padrão. Embora os valores de cota d'água estimados para 2014 serem similares para ambos os métodos de classificação, o mesmo não ocorreu para o ano anterior. A discrepância substancial entre as abordagens de classificação para 2013 está relacionada com a extração das margens do reservatório, visto que a diferença de área extraída entre os métodos foi de 26218 *pixels*. Para o ano posterior (2014), a diferença foi de 1120 *pixels*.

4.6 Volume Estimado do Reservatório em 2013 e 2014

A estimativa de volume do reservatório foi feita por meio da Equação 50, na qual foram utilizadas as profundidades indicadas pelas cotas de água estimadas e também partir das divulgadas pela Sabesp, além da superfície do espelho d'água definido nas classificações OBIA e SVM. Os resultados obtidos são mostrados na Tabela 19.

Tabela 19 - Volume do reservatório obtido a partir das cotas estimadas e divulgadas pela Sabesp

Classificação	Volume – 2013 (milhões de m ³)		Volume – 2014 (milhões de m ³)	
	Cota estimada	Cota Sabesp	Cota estimada	Cota Sabesp
OBIA	585,75	591,82	173,83	169,98
SVM	607,87	592,65	174,74	170,04
Sabesp	597,47		170,58	

Conforme a Tabela 19, os volumes estimados pelas delimitações obtidas por SVM foram maiores do que aqueles estimados por OBIA. De fato, essa superioridade nos valores estimados por SVM era esperada, pois tanto as áreas extraídas do reservatório como as estimações das cotas foram mais elevadas, quando considerado esse método de classificação por *pixel*.

Os volumes divulgados pela Sabesp para as datas de 9 de setembro 2013 e 30 de julho de 2014 foram, respectivamente, 597,4672 e 170,5778 milhões de metros cúbicos. Com a finalidade de facilitar a análise dos resultados, foram calculadas as discrepâncias entre os volumes estimados e divulgados pela Sabesp nas duas datas (Tabela 20).

Tabela 20 - Discrepâncias entre os volumes estimado e informado pela Sabesp

Classificação	$V_{estimado} - V_{SABESP}$ [2013] (milhões de m ³)		$V_{estimado} - V_{SABESP}$ [2014] (milhões de m ³)	
	Cota estimada	Cota Sabesp	Cota estimada	Cota Sabesp
OBIA	-11,71	-5,65	3,26	-0,60
SVM	10,40	-4,82	4,16	-0,54

Conforme pode ser visto na Tabela 20, os volumes estimados para 2014 são mais próximos daqueles divulgados pela Sabesp. A maior discrepância do volume calculado pode estar associada às áreas extraídas do reservatório para a região na qual o modelo de terreno foi

construído com o AW3D30, que possui acurácia mais grosseira do que os dados obtidos por levantamento batimétrico.

Apesar da diferença entre a cota d'água divulgada pela Sabesp em 2013 e a estimada por SVM ser maior, o volume calculado a partir dessa grandeza ficou mais próximo do volume divulgado oficialmente do que quando se adotou o valor estimado pelo OBIA, como pode ser visto na Tabela 20. Visto que, o mesmo ocorre quando se utiliza a cota observada pela Sabesp, o fator de maior influência pode ter sido a diferença entre as áreas extraídas por SVM e OBIA.

Por outro lado, para 2014, os volumes calculados a partir das cotas divulgadas e das estimadas apresentaram valores similares entre as abordagens. Devido à proximidade da cota estimada com a informada, o volume estimado por OBIA ficou mais aproximado do divulgado. Contudo, quando se utiliza o valor de cota da Sabesp, a estimação a partir da delimitação por SVM, ligeiramente, se assemelha mais ao volume divulgado.

Todavia, a discrepância não é a forma adequada para analisar o desempenho da estimativa temporal de volume, pois a incerteza do volume estimado varia conforme os valores dessa grandeza. Portanto, a abordagem de diferença relativa, descrita pela Equação 55, é mais apropriada para a avaliação temporal dos erros na estimativa de volume. Os resultados obtidos estão dispostos na Tabela 21.

Tabela 21 - Diferença relativa entre as abordagens utilizadas para a estimativa de volume do reservatório Jaguari-Jacareí, em porcentagem

Classificação	Diferença Relativa (%) – 2013		Diferença Relativa (%) – 2014	
	Cota estimada	Cota Sabesp	Cota estimada	Cota Sabesp
OBIA	-1,96	-0,95	1,91	-0,35
SVM	1,74	-0,81	2,44	-0,31

Como pode ser observado na Tabela 21, a utilização das delimitações do reservatório obtidas por SVM se mostrou mais precisa para a estimativa de volume, com exceção da abordagem utilizando a cota d'água estimada por SVM. Apesar do valor da diferença relativa de volume ser maior na adoção da altitude do espelho d'água por SVM em 2014, a utilização da informação proveniente desse classificador se mostra mais preciso nas demais situações.

4.7 Incerteza na Estimativa de Volume

As estimações de volume foram realizadas por meio dos valores de cotas estabelecidos a partir dos resultados das classificações e das cotas informadas pela Sabesp. Todavia, a precisão da medida desta última não é conhecida. Portanto, foram considerados dois cenários para a propagação da incerteza inerente ao cálculo de profundidade utilizando os valores divulgados pela responsável do reservatório. No primeiro, considera-se a grandeza como absoluta, ou seja, livre de erros durante a observação e, no outro, que a observação da cota possui 0,30 metros de precisão.

Pelo fato da altitude da lâmina d'água em 2013 estar acima do ponto mais elevado medido no levantamento batimétrico (830,13 metros), nas regiões em que foram utilizados os dados AW3D30 para a determinação de profundidade, a propagação do volume para 2013 se deu em dois intervalos: acima da cota de 830,13 metros utilizou-se a acurácia do AW3D30, e abaixo desse valor foi utilizada a dos dados batimétricos.

As propagações de erros da estimativa de profundidade estão dispostas na Tabela 22, em que se considera a acurácia do MDS do AW3D30 igual a 5 metros e 0,16 metros para o levantamento batimétrico. Além disso, foram adotadas as precisões da estimativa da cota d'água, indicadas na Tabela 18.

Tabela 22 – Valores resultantes da propagação de erros para estimativa da profundidade do corpo d'água

	2013		2014
	$\sigma_{h>830,13}$ (m)	$\sigma_{h<830,13}$ (m)	σ_h (m)
Cota estimada (OBIA)	6,10	3,50	2,18
Cota estimada (SVM)	6,25	3,76	2,22
Cota divulgada	5,00	0,16	0,16
Cota divulgada \pm 0,30 m	5,01	0,34	0,34

As propagações de qualidade para os cenários propostos (com e sem precisão de 0,30 m) quando se utiliza as cotas divulgadas pela Sabesp, possuem praticamente valores iguais para ambas as abordagens, como pode ser observado na Tabela 22. Conforme o esperado, a estimativa de profundidade a partir da cota obtida por OBIA mostrou-se mais precisa, dado que esta medida foi estabelecida com maior precisão do que por SVM, em concordância com o exposto na Tabela 18.

A propagação do erro na estimação do volume é dada pela Equação 51, na qual foram aplicados os valores de desvios-padrão para o *pixel*, no processo de estimação de área de A_g , $S(\hat{A}_{Ag_{pixel}})$ (Tabela 17), e as precisões da profundidade estimada (Tabela 22). Os valores propagados estão dispostos na Tabela 23.

Tabela 23 – Valores resultantes da propagação de erros na estimação de volume a partir da abordagem OBIA e SVM

Classificação	σ_V em milhões de m ³ (2013)			σ_V em milhões de m ³ (2014)		
	Cota estimada	Cota Sabesp	Cota Sabesp ± 0,30 m	Cota estimada	Cota Sabesp	Cota Sabesp ± 0,30 m
OBIA	0,1144	0,0493	0,0501	0,0458	0,0068	0,0092
SVM	0,1223	0,0528	0,0535	0,0463	0,0058	0,0097

Conforme pode ser visto na Tabela 23, embora os erros propagados na estimação de volume apresentem valores similares para as duas abordagens, esses foram menores para OBIA, com exceção de um cenário, no qual foi utilizada a cota divulgada como uma informação absoluta no ano de 2014.

Além disso, os resultados das propagações para o ano de 2014 foram inferiores do que para o ano anterior. Isso ocorre devido à área do corpo d'água que estava menor nessa época e, também, pelo fato de ter sido utilizado somente o conjunto de dados de batimetria para a determinação de profundidade para esse ano.

Contudo, a análise isolada dos valores na Tabela 23 pode levar à conclusão precipitada de que a estimação para a época de 2014 foi mais acurada do que para 2013. A fim de avaliar a proporção que a propagação de erro representa no volume estimado, realiza-se a razão entre as duas grandezas. Os resultados obtidos são apresentados na Tabela 24.

Tabela 24 – Relação entre a incerteza e o volume estimado em porcentagem

Classificação	σ_V em relação ao volume estimado (%) - 2013			σ_V em relação ao volume estimado (%) - 2014		
	Cota estimada	Cota Sabesp	Cota Sabesp ± 0,30 m	Cota estimada	Cota Sabesp	Cota Sabesp ± 0,30 m
OBIA	0,0195	0,0083	0,0085	0,0263	0,0040	0,0054
SVM	0,0201	0,0089	0,0090	0,0265	0,0034	0,0057

De acordo com a Tabela 24, a proporção do volume estimado que pode ser atribuída a propagação de erros equivale a menos de 0,03% do volume estimado em todas as situações, mostrando a considerável acurácia que o método pode alcançar e quão similares foram as abordagens adotadas, quando comparadas no mesmo cenário.

Embora, ao considerar a propagação a partir da cota estimada, os erros inerentes as informações de profundidade sejam maiores para as estimações de 2013, a proporção que os erros representam no volume estimado em 2013 é menor do que 2014. Os erros provenientes da área do *pixel* podem ser o fator determinante na ocorrência desse fenômeno, visto que, a área estimada de *Ag* foi obtida com maior precisão nas classificações para o ano de 2013, como pode ser visto na Tabela 17.

A fim de analisar espacialmente as variações da incerteza associadas a cada abordagem para a estimativa de volume, foram elaborados mapas expressando o desvio padrão ao longo do reservatório Jaguari-Jacareí, considerando cada configuração utilizada em 2013 (Figura 27) e 2014 (Figura 28).

Figura 27 - Representação espacial das incertezas associadas a cada método utilizado para estimar o volume do Jaguari-Jacareí, em 2013

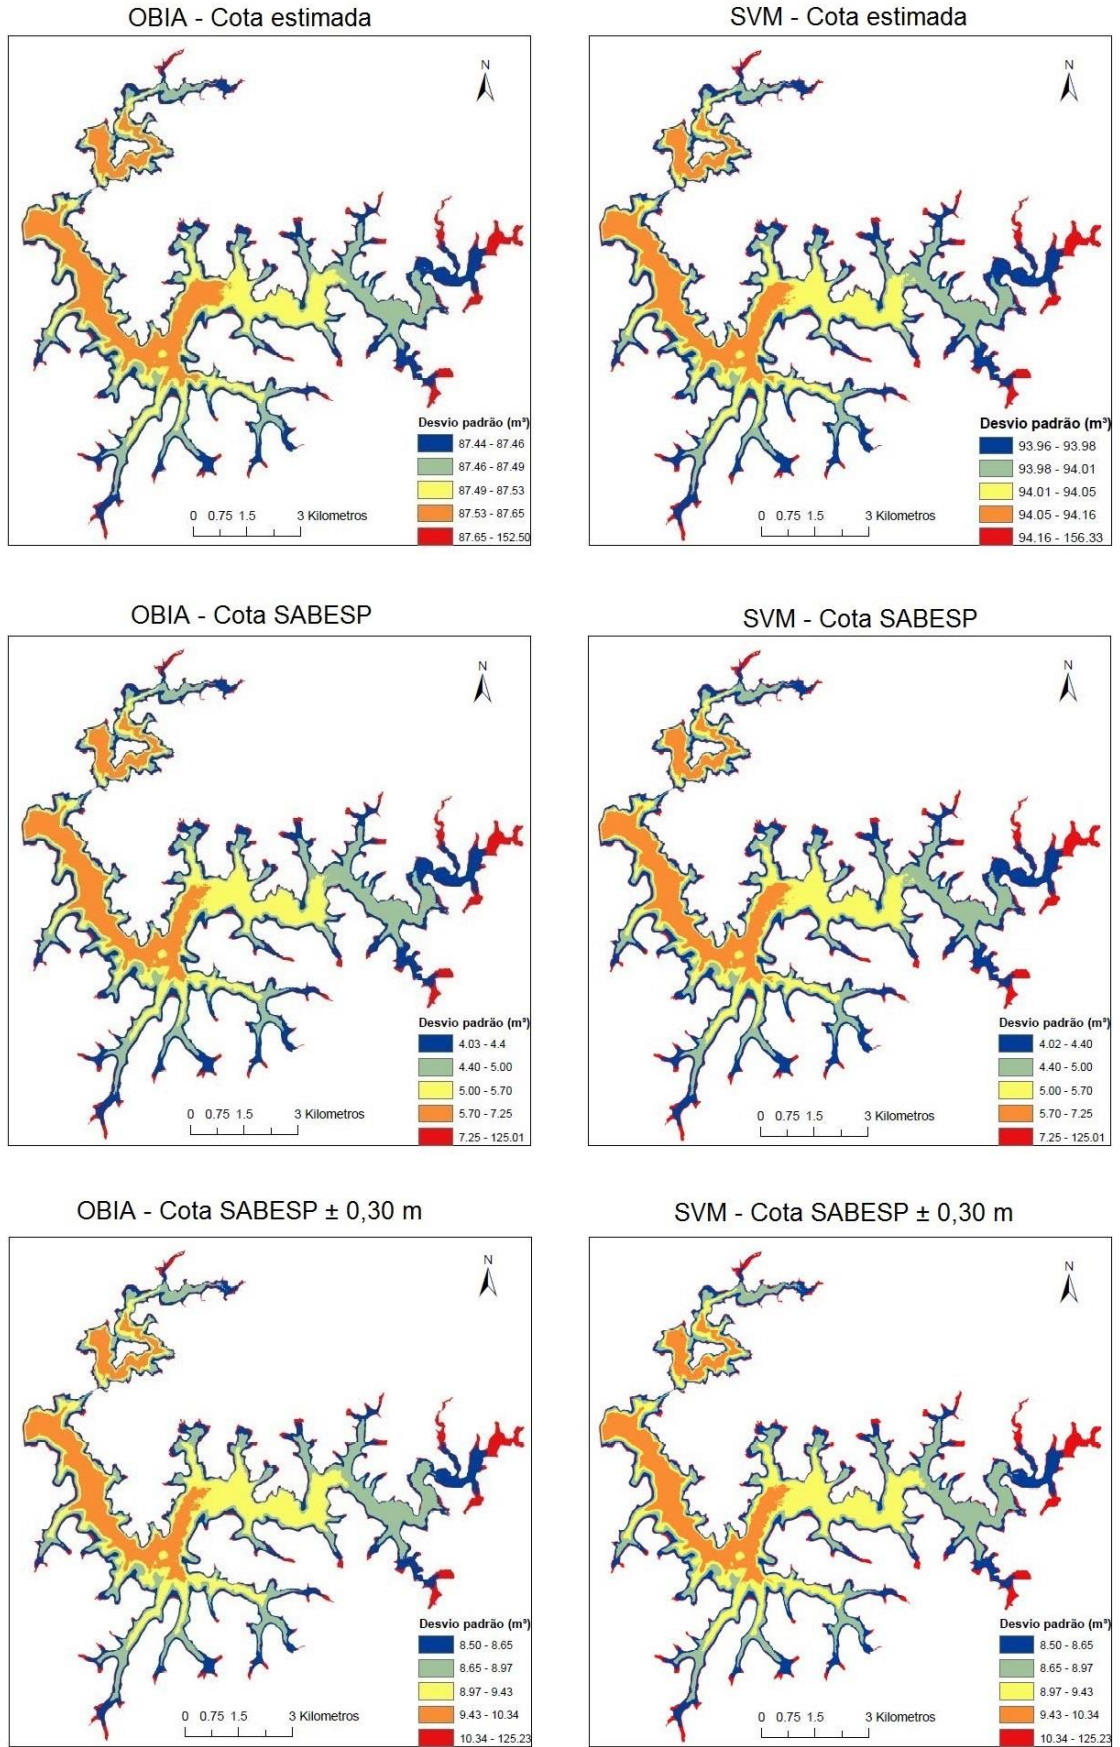
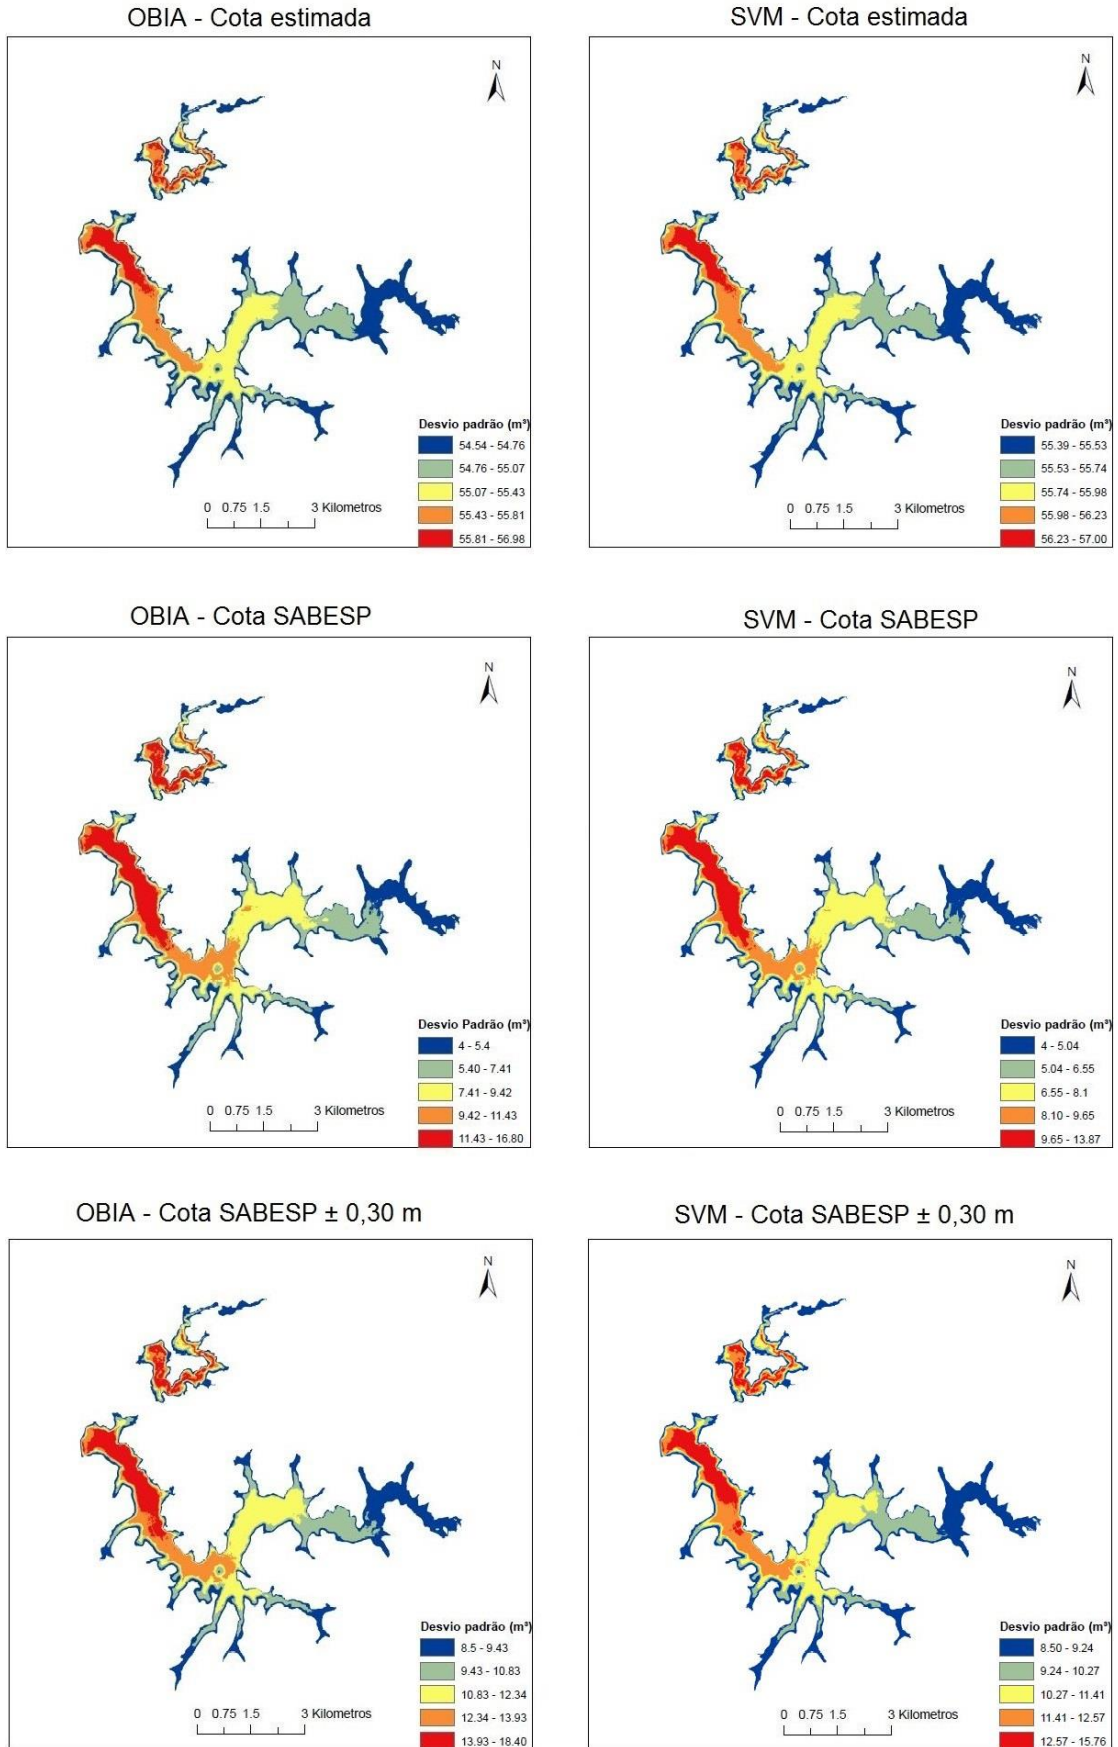


Figura 28 - Representação espacial das incertezas associadas a cada método utilizado para estimar o volume do Jaguari-Jacareí, em 2014



Conforme pode ser visto nas Figuras 27 e 28, as incertezas associadas à estimativa de volume estão diretamente relacionadas com a profundidade do reservatório. Além disso, a ordem de grandeza dos desvios-padrão é proporcional à qualidade da informação da altitude do espelho d'água utilizada para o cálculo de volume. Sendo assim, a hierarquia de fontes de dados que resultaram em menor erro foram: cotas da Sabesp como absolutas; cotas da Sabesp $\pm 0,30$ m e as cotas estimadas pelas delimitações do reservatório. Por fim, pode-se verificar na Figura 27 que as áreas de maior incerteza estão próximas às margens, locais menos profundos. Esse fato ocorre, pois, nessas posições, foram utilizados dados provenientes do AW3D30 para a construção do MDT utilizado como referência de relevo submerso para o cálculo de volume.

5 CONCLUSÕES E RECOMENDAÇÕES

A informação produzida por meio da classificação de imagens mostrou-se adequada para o monitoramento de recursos hídricos, resultando em mapeamentos de alta acurácia temática. Os tipos de cobertura da terra associados a corpos d'água, vegetação arbórea, vegetação rasteira, solo exposto e áreas impermeáveis foram discriminados tanto pela abordagem de classificação por pixel (SVM), como baseada em objeto (OBIA) para as imagens tomadas em 2013 e 2014.

Na análise da qualidade das classificações resultantes foram consideradas as concordâncias e discrepâncias expressas na matriz de confusão de cada classificação produzida e verificou-se que, com exceção da classe área impermeável (*Im*), a discriminação dos demais tipos de cobertura apresentou elevada concordância com os dados de referência. A comparação do desempenho entre os métodos de classificação empregados indicou que a abordagem baseada em *pixel* resultou em indicadores de acurácia superiores à classificação OBIA, em 2013 e 2014 e, portanto, mostrou-se mais adequada para o mapeamento temático dos tipos de cobertura da terra no entorno do reservatório Jaguari-Jacareí.

A análise das mudanças ocorridas na paisagem de entorno do reservatório Jaguari-Jacareí durante a crise hídrica, realizada a partir da intersecção dos mapas temáticos de 2013 e 2017 produzidos pelos classificadores SVM e OBIA individualmente, indicou os tipos de cobertura que ocuparam as margens do reservatório com a redução da superfície do corpo d'água durante a crise hídrica. Enquanto o classificador SVM mapeou como solo exposto e vegetação rasteira ou arbórea áreas antes (em 2013) ocupadas por água, a abordagem OBIA resultou em uma área quase quatro vezes maior atribuída a área impermeável. Essa constatação é desfavorável à OBIA, haja vista que os únicos objetos impermeáveis presentes na área são a infraestrutura da barragem, píeres e o afloramento rochoso do canal que interliga os rios Jaguari e Jacareí. Em relação à detecção do corpo d'água, ambas as abordagens resultaram em áreas similares em 2013 (35,37 km² por OBIA contra 36,24 km² por SVM) e 2014 (17,51 km² por OBIA e 17,46 km² por SVM), indicando que teve sua superfície reduzida em quase 50% com a crise hídrica.

Visando a representação do relevo submerso do reservatório Jaguari-Jacareí, foi gerado um MDT, usando dados obtidos por batimetria, complementados pelo MDE AW3D30, além da cota de 830,13 m. Foram considerados dois cenários no cálculo de volume: utilizando a cota de água divulgada pela Sabesp e a cota estimada obtida pela intersecção entre as delimitações do reservatório extraídas por classificação de imagens e o MDT. Obviamente, os

volumes estimados a partir das cotas divulgadas pela Sabesp se aproximaram mais dos valores divulgados pela própria companhia e, nesse processo, a obtenção da superfície do corpo d'água derivado do SVM se mostrou mais acurado para a posterior a estimação de volume.

A qualidade da informação de volume produzida foi pela propagação de incertezas sobre o modelo matemático e a acurácia dos dados utilizados no processo de estimação de volume. Nesse caso, os três cenários considerados para a propagação de erro no cálculo do volume foram: uma partir da cota estimada, por meio da cota divulgada pela Sabesp, na qual uma considera a informação como absoluta e, a cota divulgada pela Sabesp associada a uma incerteza de 0,30m. Os resultados se mostraram quase equivalentes nas três abordagens, porém o cenário em que se adotou a cota divulgada pela Sabesp como absoluta, propagou menor incerteza no cálculo de volume.

Como recomendação para futuras investigações sugere-se o uso de imagens orbitais de diferentes resoluções espaciais, a fim de analisar a relação entre o detalhamento na representação do reservatório com a estimação de seu volume. Pois, se imagens adquiridas em resoluções espaciais mais grosseiras que a do RapidEye obtiverem resultados similares aos desta pesquisa, a metodologia proposta pode ser empregada com maior regularidade, visto que, sistemas sensores como o OLI/Landsat-8 e o MSI/Sentinel-2 adquirem dados espaçados em 16 e 10 dias, respectivamente.

Outra possibilidade é a desenvolver e validar modelo empírico que relacione a área da superfície do espelho d'água e o volume do reservatório. Para isso é necessário recorrer a uma série histórica de imagens e respectivos volumes divulgados em data coincidente, representando épocas tanto de escassez como de cheia do corpo d'água para que se possa ajustar matematicamente o modelo. Com isso, pode-se reduzir a necessidade de uso de dados altimétricos em estimativas do volume de água.

6 REFERÊNCIAS

- AGÊNCIA NACIONAL DE ÁGUAS – ANA (2013). Dados de referência acerca da outorga do Sistema Cantareira. Disponível em: <http://audienciapublica.ana.gov.br/arquivos/Aud_001_2014_DadosdeReferenciaAcercadaOutorgadoSistemaCantareira.pdf>. Acesso em: 15 jul. 2016.
- AGÊNCIA NACIONAL DE ÁGUAS – ANA (2015a). Conjuntura dos recursos hídricos no Brasil – Informe 2014. Disponível em <<http://www3.snirh.gov.br/portal/snirh/centrais-de-conteudos/conjuntura-dos-recursos-hidricos/informes2014.pdf>>. Acesso em: 10 mar. 2016.
- AGÊNCIA NACIONAL DE ÁGUAS – ANA (2015b). Encarte Especial sobre a Crise Hídrica: Conjuntura dos recursos hídricos no Brasil – Informe 2014. Disponível em <<http://conjuntura.ana.gov.br/docs/crisehidrica.pdf>>. Acesso em: 10 mar. 2016.
- ALSDORF, D.; RODRÍGUEZ, E.; LETTENMAIER, D. Measuring surface water from space. *Reviews of Geophysics*, v. 45, i. 2, 1-24, 2007
- ANDERSON, J.; HARDY, E.; ROACH, J.; WITMER, R. A land use and land cover classification system for use with remote sensor data. Disponível em: <<http://pubs.usgs.gov/pp/0964/report.pdf>>. Acesso em: 22 de jun. de 2016.
- ANTUNES, A. *Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial*. 147 f. 2003. Tese (Doutorado em Ciências Geodésicas) Universidade Federal do Paraná, Curitiba, 2003.
- BAATZ, M.; SCHÄPE, A. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. Disponível em: <http://www.ecognition.cc/download/baatz_schaepe.pdf>. Acesso em: 15 de mar. de 2016.
- BAZARAA, M; SHERALI, H.; SHETTY, C. *Nonlinear programming: theory and algorithms*. 3. ed. Hoboken: John Wiley & sons, 2006, 853 p.
- BELAL, A.; MOGHANM, F. Detecting urban growth using remote sensing and GIS techniques in Al Gharbiya governorate, Egypt. *The Egyptian Journal of Remote Sensing and Space Sciences*, v. 14, 73-79, 2011

- BLASCHKE, T. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 65, p. 2-16, 2010.
- BLASCHKE, T.; GLÄSSER, C.; LANG, S. Processamento de imagens num ambiente integrado SIG/sensoriamento remoto – tendências e consequências. Tradução de Herman Kux. In: BLASCHKE, T. e KUX, H. (Org.). *Sensoriamento remoto e SIG avançados: novos sistemas sensores; métodos inovadores*. São Paulo: Oficina de Textos, 2007. p. 11-18.
- BLASCHKE, T.; HAY, G.; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; FEITOSA, R.; VAN DER MEER, F.; VAN DER WERFF, H.; VAN COILLIE, F.; TIEDE, D. Geographic object-based image analysis – towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 87, p.180-191, 2014.
- BO, S.; HAN, X. Parameter segmentation in object-oriented classification of remotely sensed imagery. In: *International Conference on Intelligent Technology and Automation*, 3, 2010, Changsha. **Proceedings...** Piscataway: IEEE, 2010. P. 876-879.
- BURNETT, C.; BLASCHKE, T. A multi-scale segmentation/object relationship modelling methodology for landscape analysis. *Ecological Modelling*, v. 168, p. 233-249, 2003.
- CÂMARA MUNICIPAL DA ESTÂNCIA TURÍSTICA DE JOANÓPOLIS Plano diretor do município de Vargem. Disponível em: <<http://www.camarajoanopolis.sp.gov.br/planodiretor>>. Acesso em: 15 de ago. de 2016.
- CASTLEMAN, K. *Digital image processing*. Upper Saddle River: Prentice Hall, 1996.
- CLARKE, D.; CLARK, D. Lineage. In: Guptill, S.; Morrison, J. (Eds.). *Elements of Spatial Data Quality*. Oxford: Pergamon Press, 1995, p. 13-30.
- CLÉMENT, V.; GIRAUDON, G.; HOUZELLE, S.; SANDAKLY, F. Interpretation of remotely sensed images in a context of multisensor fusion using a multispecialist architecture. *IEEE Transactions on Geoscience and Remote Sensing*, v. 31, n. 4, p. 779-791, 1993.
- COMPANHIA DE SANEAMENTO BÁSICO DO ESTADO DE SÃO PAULO – Sabesp. Levantamento Batimétrico do Sistema Cantareira. São Paulo: Sabesp, 2008.
- CONGALTON, R; GREEN, K. *Assessing the accuracy of remotely sensed data: Principles and practices*. Boca Raton: CRC Press, 1999, p. 43-53.

- DAS, K.; RAVAN, S.; NEGI, S.; JAIN, A.; ROY, P. Forest cover monitoring using remote sensing and GIS — A case study in Dhaukhand range of Rajaji National Park, Uttar pradesh. *Journal of the Indian Society of Remote Sensing*, v. 24, i. 1, p. 33-42, 1996.
- DAVIES, E. *Machine Vision: theory, algorithms and practicalities*. 3. ed. San Francisco: Morgan Kaufmann Publishers, 2005, p. 719-720.
- DI GREGORIO, A. JANSEN, L. Land cover classification system. Disponível em: <<http://www.fao.org/docrep/003/x0596e/x0596e00.HTM>>. Acesso em: 22 de jun. de 2016.
- DURO, D.; FRANKLIN, S.; DUBÉ, M. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing of Environment*, v. 118, p. 259-272, 2012.
- EL-HATTAB, A. Single beam bathymetric data modelling techniques for accurate maintenance dredging. *The Egyptian Journal of Remote Sensing and Space Sciences*, v. 17, p. 189-195, 2014.
- EL-SHEIMY, N.; VALEO, C.; HABIB, A. **Digital terrain modeling**: acquisition, manipulation and applications. Boston: Artech House, 2005
- EUROPEAN ENVIRONMENT AGENCY. CORINE land cover. Disponível em: <http://www.eea.europa.eu/publications/COR0-landcover/at_download/file>. Acesso em: 22 de jun. de 2016.
- FEITOSA, R. et al. Ajuste automático de parâmetros de segmentação. In: BLASCHKE, T. e KUX, H. (Org.). *Sensoriamento remoto e SIG avançados: novos sistemas sensores; métodos inovadores*. São Paulo: Oficina de Textos, 2007. p. 129-144.
- FOODY, G.; MATHUR, A. Toward intelligent training of supervised image classification: directing training data acquisition for SVM classification. *Remote Sensing of Environment*, v. 93, p. 107-117, 2004.
- FORSYTH, D.; PONCE, J. *Machine Vision: a modern approach*. Upper Saddle River: Prentice Hall, 2003, 693 p.
- GONZALEZ, R.; WOODS, R. *Digital image processing*. ed. 3. Upper Saddle River: Pearson Prentice Hall, 2008, p. 443-445.

- HAN, X.; CHEN, X.; FENG, L. Four decades of winter wetlands changes in Poyang Lake based on Landsat observations between 1973 and 2013. *Remote Sensing of Environment*, v. 156, p. 426-437, 2015.
- HATHOUT, S. The use of GIS for monitoring and predicting urban growth in east and west St Paul, Winnipeg, Manitoba, Canada. *Journal of Environmental Management*, v. 66, i. 3, p.229-38, 2002.
- HAY, G.; BLASCHKE, T.; MARCEAU, D.; BOUCHARD, A. A comparison of three image-object methods for the multiscale analysis of landscape structure. *ISPRS Journal of Photogrammetry & Remote Sensing*, v. 57, p. 327-345, 2003.
- HAY, G.; CASTILLA, G. Geographic object-based image analysis (GEOBIA): a new name for a new discipline. In: BLASCHKE, T.; LANG, S.; HAY, G. (Eds.). *Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications*. Berlin: Springer-Verlag, 2008, p. 75-90.
- HEGAZY, I.; KALOOP, M. Monitoring urban growth and land use change detection with GIS and remote sensing techniques in Daqahlia governorate Egypt. *International Journal of Sustainable Built Environment*, v. 4, i. 1, p. 117-124, 2015.
- HEROLD, M.; ROBERTS, D. The spectral dimension in urban remote sensing. In: RASHED, T.; JÜRGENS, C. (Eds.). *Remote Sensing of Urban and Suburban areas*. Berlin: Springer-Verlag, 2010, p. 47-65.
- HUNTER, G.; BREGT, A.; HEUVELINK, G.; DE BRUIN, S.; VIRRANTAU, K. Spatial data quality: problem and prospects. In: NAVRATIL, G. (Ed.). *Research Trends in Geographic Information Science*. Berlin: Springer-Verlag, 2009, p. 101-121.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. Manual técnico de uso da terra. 3. ed. Disponível em: <<http://biblioteca.ibge.gov.br/visualizacao/livros/liv81615.pdf>>. Acesso em: 22 de jun. de 2016
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Resolução nº 23**. Rio de Janeiro: IBGE, 1989.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. *ISO 19157:2013: geographic information – data quality*. Geneva: ISO, 2013. 170p.

- IZENMAN, A. *Modern multivariate statistical techniques: regression, classification, and manifold learning*. New York: Springer, 2008, p. 369-404.
- JACOBI, P.; CIBIM, J.; LEÃO, R. Crise hídrica na macrometrópole paulista e repostas da sociedade civil. *Estudos Avançados*, São Paulo, v. 29, n. 84, 2015, p. 27-42.
- JAPAN AEROSPACE EXPLORATION AGENCY – JAXA ALOS Global digital surface model “ALOS World 3D – 30m” (AW3D30). Disponível em: <<http://www.eorc.jaxa.jp/ALOS/en/aw3d30/>>. Acesso em: 20 de fev. de 2017
- JENSEN, J. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução de José Carlos Neves Epiphanyo (coordenador).. [et al.]. São José dos Campos: Parêntese, 2011.588p
- KAGANAMI, H.; BEIJI, Z. Region-based segmentation versus edge detection. In: *International Conference on Intelligence Hiding and Multimedia Signal Processing*, 5., 2009, Kyoto **Proceedings...** Piscataway: Institute of Electrical and Electronics Engineers, 2009, p. 1217-1221.
- KALKAN, K.; BAYRAM, B.; MAKTAV, D.; SUNAR, F. Comparison of support vector machine and object base classification methods for coastline detection. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Antalya, Túrquia, 2013. **Proceedings..** Antalya: ISPRS, 2013, p. 125-127.
- KAMPOURAKI, M.; WOOD, G.; BREWER, T. Opportunities and limitations of object-based image analysis for detecting urban impervious and vegetated surfaces using true-colour aerial photography. In: BLASCHKE, T.; LANG, S.; HAY, G. (Eds.). *Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications*. Berlin: Springer-Verlag, 2008, p. 555-570.
- KHATAMI, R.; MOUNTRAKIS, G.; STEHMAN, S. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*, v. 177, 89-100, 2016.
- LAMONACA, A.; CORONA, P.; BARBATI, A. Exploring forest structural complexity by multi-scale segmentation of VHR imagery. *Remote Sensing of Environment*, v. 112, p. 2839-2849, 2008.

- LANG, S. A utilização do conceito de totalidade (holismo) na geração e planos de segmentação regionalizadas em conjuntos de imagens de altíssima resolução. In: BLASCHKE, T.; KUX, H. (Orgs.). *Sensoriamento remoto e SIG avançados*. São Paulo: Oficina de Textos, 2007, p. 39-46.
- LANG, S. Object-based image analysis for remote sensing applications: modelling reality – dealing with complexity. In: BLASCHKE, T.; LANG, S.; HAY, G. (Eds.). *Object-based image analysis: Spatial concepts for knowledge-driven remote sensing applications*. Berlin: Springer-Verlag Berlin Heidelberg, 2008, p. 3-28.
- LAPUCHA, D.; MAYNARD, K. *Investigation of the real-time accuracy of the DGPS method*. Fort Belvoir: U.S. Army Topographical Engineering Center, 1992.
- LIEDTKE, C.; BÜCKNER, J.; GRAU, O.; GROWE, S.; TÖNJES, R. AIDA: a system for the knowledge based interpretation of remote sensing data. In: 3rd *International Airborne Remote Sensing Conference and Exhibition*, 1997, Copenhagen, Denmark. *Anais...* Copenhagen, 1997, p. 313-320.
- LILLESAND, T.; KIEFER, R. **Remote sensing and image interpretation**. 2. ed. Toronto: John Wiley and Sons, 1987.
- LIU, D.; Xia, F. Assessing object-based classification: advantages and limitations. *Remote Sensing Letters*, v. 1, n. 4, p. 187-194, 2010.
- LÓPEZ, F. *Calidad en la producción cartográfica*. Madrid: Ra-ma, 2002
- LORENA, A; CARVALHO, A. Uma introdução às Support Vector Machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43-67, 2007.
- MATSUYAMA, T.; HWANG, V. *SIGMA*: a knowledge-based aerial image understanding system. New York: Springer, 1990, 277 p.
- McKEOWN, D.; WILSON, A; McDERMOTT. Rule-based interpretation of aerial imagery. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. PAMI-7, n. 5, p. 570-585, 1985.
- MONICO, J. **Posicionamento pelo GNSS**: descrição, fundamentos e aplicações. 2. ed. São Paulo: Editora UNESP, 2008.
- MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*. v. 66, p. 247-259, 2011.

- MUALA, E.; MOHAMED, Y.; DUAN, Z.; VAN DER ZAAG, P. Estimation of reservoir discharges from Lake Nasser and Roseires reservoir in the Nile basin using satellite altimetry and imagery data. *Remote Sensing*, v. 6, p. 7522-7545, 2014.
- MYINT, S; GOBER, P.; BRAZEL, A.; GROSSMAN-CLARKE, S., WENG, Q. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, v. 115, p. 1145-1161, 2011.
- NOVO, E. **Sensoriamento Remoto: princípios e aplicações**. 3. ed. São Paulo: Blucher, 2008.
- PINHO, C. *Análise orientada a objetos de imagens de satélites de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intra-urbano: o caso de São José dos Campos*. 2005. 176 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.
- PLANET. RapidEye™ imagery product specifications. Disponível em: <<https://www.planet.com/products/satellite-imagery/files/160625-RapidEye%20Image-Product-Specifications.pdf>>. Acesso em: 15/01/2017.
- PREFEITURA DO MUNICÍPIO DE BRAGANÇA PAULISTA Plano diretor do município de Bragança paulista. Disponível em: <<http://www.braganca.sp.gov.br/newsite/content.php?mid=119&unc=1470237855>>. Acesso em: 15/08/2016.
- PREFEITURA MUNICIPAL DE PIRACAIA Plano diretor do município de Piracaia. Disponível em: <http://www.piracaia.sp.gov.br/novo_site/plano_diretor/documentos/2007/20100407122125.pdf>. Acesso em: 15/08/2016.
- PREFEITURA DO MUNICÍPIO DE VARGEM Plano diretor do município de Vargem. Disponível em: <http://www.vargem.sp.gov.br/novo_site/index.php?nivel=0&exibir=plano_diretor&ID=38>. Acesso em: 15 de ago. de 2016.
- OLOFSSON, P.; FOODY, G.; HEROLD, M.; STEHMAN, S.; WOODOCK, C.; WULDER, M. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, p. 42-57, 2014.

- REDDY, C.; JHA, C.; DADHWAL, W. Assessment and monitoring of long-term forest cover changes in Odisha, India using remote sensing and GIS. *Environmental Monitoring and Assessment*, v. 185, i. 5, p. 4399-4415, 2013.
- RIAZANOFF, S.; SANTER, R. Quality of raster data. In: DEVILLERS, R.; JEANSOULIN, R. (Eds.). *Fundamentals of spatial data quality*. London: Iste, 2006, p. 61-87.
- RICHARDS, J. *Remote sensing digital image analysis*. ed. 5. New York: Springer, 2013.
- SABESP. Divulgação informações mananciais. Disponível em: <<http://www2.Sabesp.com.br/mananciais/DivulgacaoSiteSabesp.aspx>>. Acesso em: 27 de jul. 2016.
- SCHOWENGERDT, R. *Remote sensing: models and methods for image processing*. ed. 3. San Diego: Academic Press, 2007.
- SCHWEIE, J.; TUFTE, L. O potencial de procedimentos baseados em regiões para a avaliação integrada de dados de SIG e sensoriamento remoto. In: BLASCHKE, T.; KUX, H. (Orgs.). *Sensoriamento remoto e SIG avançados*. São Paulo: Oficina de Textos, 2007, p. 56-65.
- SONG, M.; CIVCO, L.; HURD, D. A competitive pixel-object approach for landcover classification. *International Journal of Remote Sensing*, v. 26, n. 22, p. 4981-4997, 2005.
- STEHMAN, S. Estimating area from an accuracy assessment error matrix. *Remote Sensing of Environment*, 132, p. 202-211, 2013.
- STEIN, A.; VAN OORT, P. The impact of positional accuracy on the computation of cost functions. In: DEVILLERS, R.; JEANSOULIN, R. (Eds.). *Fundamentals of spatial data quality*. London: Iste, 2006, p. 107-122.
- TADONO, T.; NAGAI, H.; ISHIDA, H.; ODA, F.; NAITO, S.; MINAKAWA, K.; IWAMOTO, H. Generation of the 30 m-mesh global digital surface model by ALOS PRISM. In: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Praga, República Tcheca, 2016. **Proceedings...** Praga: ISPRS, 2016, p. 157-162.
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. ed. 4. San Diego: Academic Press, 2008, p. 93-116.

- TRIMBLE. *Trimble documentation: eCognition Developer 9.0 – reference book*. Munique: Trimble, 2014, 446 p.
- VAN COILIE, F.; VERBEKE, L.; DE WULF, R. Semi-automated forest stand delineation using wavelet based segmentation of very high resolution optical imagery. In: BLASCHKE, T.; LANG, S.; HAY, G. (Eds.). *Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications*. Berlin: Springer-Verlag, 2008, p. 237-256.
- VAN OORT, P. *Spatial data quality: from description to application*. Rotterdam: NCG, 2005.
- VAPNIK, V. *Statistical Learning Theory*. New York: John Wiley & Sons, Inc., 1998.
- VAPNIK, V. *The nature of statistical learning theory*. ed. 2. New York: Springer Verlag, 2000, 314 p.
- VEREGIN, H. Data quality parameters. In: LONGLEY, P. et al. (Eds.). *Geographical information systems: principles, techniques, management and applications*. ed. 2. New York: John Wiley and Sons, 1999, p. 177-189.
- VIERA, A.; GARRETT, J. Understanding Interobserver Agreement: The Kappa Statistic, *Family Medicine*, v. 37, p. 360-363, 2005.
- WHITESIDE, T.; BOGGS, G.; MAIER, S. Comparing object-based and pixel-based classifications for savannas. *International Journal of Applied Earth Observation and Geoinformation*, v. 13, p. 884-893, 2011.
- WOLF, P.; GHILANI, C. *Adjustment computations: statistics and least squares in surveying and GIS*. New York: John Wiley and Sons, 1997.
- WULDER, M.; HALL, R.; FRANKLIN, S. Remote sensing and GIS applications on forestry. In: ARONOFF, S. (Ed.). *Remote sensing for GIS managers*. Berlin: Springer-Verlag, 2004, p. 351-356.
- ZHU, W.; JIA, S.; LV, A. Monitoring the fluctuation of lake Qinghai using multi-source remote sensing data. *Remote Sensing*, v. 6, p. 10457-10482, 2014.