

Rodolfo Luiz Cugler Pereira

# **Abordagem colaborativa para segmentação de áreas degradadas e regeneradas**

**Sorocaba, SP**

**27 de Maio de 2020**



Rodolfo Luiz Cugler Pereira

## **Abordagem colaborativa para segmentação de áreas degradadas e regeneradas**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação (PPGCC-So) da Universidade Federal de São Carlos como parte dos requisitos exigidos para a obtenção do título de Mestre em Ciência da Computação. Linha de pesquisa: Computação científica e inteligência computacional.

Universidade Federal de São Carlos – UFSCar

Centro de Ciências em Gestão e Tecnologia – CCGT

Programa de Pós-Graduação em Ciência da Computação – PPGCC-So

Orientador: Prof. Dr. Siovani Cintra Felipussi

Coorientador: Prof. Dr. André Luis Debiaso Rossi

Sorocaba, SP

27 de Maio de 2020

Pereira, Rodolfo Luiz Cugler

Abordagem colaborativa para segmentação de áreas degradadas e regeneradas / Rodolfo Luiz Cugler Pereira -- 2020.  
114f.

Dissertação (Mestrado) - Universidade Federal de São Carlos, campus Sorocaba, Sorocaba  
Orientador (a): Siovani Cintra Felipussi  
Banca Examinadora: Márcio Alexandre Marques, Tiago Agostinho de Almeida, Siovani Cintra Felipussi  
Bibliografia

1. Desmatamento. 2. Sensoriamento remoto. 3. Método de segmentação. I. Pereira, Rodolfo Luiz Cugler. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Maria Aparecida de Lourdes Mariano -  
CRB/8 6979



# UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências em Gestão e Tecnologia  
Programa de Pós-Graduação em Ciência da Computação

---

## Folha de Aprovação

---

Defesa de Dissertação de Mestrado do candidato Rodolfo Luiz Cugler Pereira, realizada em 27/05/2020, com o título: Abordagem Colaborativa para Segmentação de Áreas Degradadas e Regeneradas

### Comissão Julgadora:

Prof. Dr. Siovani Cintra Felipussi (UFSCar), participando à distância

Prof. Dr. Márcio Alexandre Marques (UNESP), participando à distância

Prof. Dr. Tiago Agostinho de Almeida (UFSCar), participando à distância

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

A Ata de Defesa, assinada pelos membros da Comissão Julgadora, consta no Sistema Eletrônico de Informações da UFSCar (SEI) e na Secretaria do Programa de Pós-Graduação em Ciência da Computação.

*A meus pais, Silvane e Gilson, e  
minha namorada, Gabriela.*

# Agradecimentos

Agradeço,

a Deus por me dar saúde e sabedoria.

a meus pais, Silvane Cugler Pereira e Gilson Carlos Pereira por me apoiarem em minhas decisões.

a minha namorada, Gabriela Ragazzoni Mangini por me encorajar a lutar pelos meus sonhos.

a meu orientador, Prof. Dr. Siovani Cintra Felipussi, e co-orientador, Prof. Dr. André Luis Deabiso Rossi, pela sabedoria transmitida.

ao Prof. Dr. Tiago Agostinho de Almeida pelos conselhos oferecidos.

ao 1º Ten PM Vitor Calandrini de Araújo do CPAmb por contribuir para a validação desse trabalho com casos reais de fiscalização.





*“Para ter um negócio de sucesso, alguém, algum dia, teve que tomar uma atitude de coragem.”*  
*(Peter Drucker)*



# Resumo

As florestas exercem considerável importância ambiental, social e econômica. Ainda assim, durante muitos anos vem sendo destruídas e transformadas em pastos, campos agrícolas, entre outros. Com a popularização das imagens de sensoriamento remoto, em específico das imagens geradas pelos satélites da série Landsat, várias pesquisas foram realizadas com o objetivo de encontrar, monitorar e analisar os índices de desmatamento, entretanto, estudos indicam que imagens com resoluções maiores possibilitam a obtenção de resultados superiores. A segmentação das imagens de sensoriamento remoto é um dos fatores cruciais para apoiar a fiscalização de áreas desmatadas. A literatura contém diferentes técnicas de segmentação e de reconhecimento de padrões que têm sido utilizadas para solucionar esse problema. Além do mais, essas pesquisas evidenciam que os resultados das abordagens híbridas são promissoras em relação ao uso dos métodos separadamente. Portanto, a presente pesquisa objetiva propor uma abordagem colaborativa para segmentação e classificação de áreas desmatadas e regeneradas. Essa abordagem utiliza quatro diferentes métodos de segmentação (SAVI, técnicas de AM, método de segmentação multi-escala e o método de segmentação *marker-controlled watershed-based*) para sugerir áreas desmatadas no Estado de São Paulo, Brasil. Os resultados foram comparados com infrações ambientais reais autuadas pela Polícia Militar Ambiental do Estado de São Paulo de forma manual e se mostraram promissores. Sendo assim, a proposta de uma abordagem colaborativa para sugestão de áreas degradadas se torna relevante como auxílio para a fiscalização dos órgãos competentes.

**Palavras-chaves:** Desmatamento. Sensoriamento Remoto. Abordagem Colaborativa. Método de Segmentação.



# Abstract

Forests have huge environmental, social and economic importance. However, over the years they have been destroyed and transformed into pastures, agricultural fields, etc. Due to the popularity of remote sensing images, specifically the images acquired by the Landsat satellite series, several studies were proposed to find, monitor and analyze deforestation rates. However, researches indicate that images with higher spatial resolutions can overcome the results. Segmentation of remote sensing images is a crucial factor to support the inspection of deforested areas. Literature has different segmentation and pattern recognition techniques that have been used to solve this problem. Furthermore, these studies show the results of hybrid segmentation methods are better than single methods. Therefore, this research proposes a collaborative framework to segment and classify deforested areas. This approach analyzes four different segmentation methods (SAVI, AM techniques, multi-scale segmentation method and the marker-controlled watershed-based segmentation method) to suggest deforested areas in the State of São Paulo, Brazil. Results were compared with real environmental infractions found by the Military Environmental Police of the State of São Paulo manually and proved to be promising. Therefore, the proposal for a collaborative approach to suggest degraded areas becomes relevant as an approach to help the inspection of deforestation by police.

**Key-words:** Deforestation. Remote Sensing. Collaborative Framework. Segmentation Method.



# Lista de ilustrações

Figura 1 – Fluxograma de processamento de imagens de SR. . . . .	25
Figura 2 – Segmentação <i>watershed</i> . . . . .	37
Figura 3 – Segmentação multi-escala. . . . .	39
Figura 4 – Imagem original. . . . .	41
Figura 5 – NDVI. . . . .	41
Figura 6 – SAVI. . . . .	41
Figura 7 – Fragmentação da imagem de SR com tamanho de 15x15 <i>pixels</i> . . . . .	43
Figura 8 – Fluxo do método desenvolvido. . . . .	49
Figura 9 – Região representada pela órbita 152 e ponto 127. . . . .	51
Figura 10 – Ferramenta de automatização executando a rotina. . . . .	52
Figura 11 – Escala mais fina gerada pelo método multi-escala. . . . .	54
Figura 12 – Escala mais grossa gerada pelo método multi-escala. . . . .	54
Figura 13 – Imagem original. . . . .	58
Figura 14 – Segmentação <i>MCWB</i> . . . . .	58
Figura 15 – Região $R_{mcwb}$ . . . . .	58
Figura 16 – Segmentação <i>SAVI</i> . . . . .	58
Figura 17 – Região $R_{savi}$ . . . . .	58
Figura 18 – Resultado da abordagem colaborativa em maio de 2018. . . . .	59
Figura 19 – Resultado da abordagem colaborativa em julho de 2018. . . . .	59
Figura 20 – Resultado da comparação entre a Figura 18 e a Figura 19 . . . . .	59
Figura 21 – Cobertura vegetal do Estado de São Paulo: i) região verde distingue a Mata Atlântica brasileira e ii) região alaranjada identifica Cerrado brasileiro. . . . .	61
Figura 22 – Autuação de desmatamento na cidade de Jacupiranga em 2017 e 2018 aplicada sobre imagem do <i>Google Earth</i> . . . . .	62
Figura 23 – Imagem capturada pela constelação RapidEye em 2011 na cidade de São José das Laranjeiras. . . . .	63
Figura 24 – Imagem capturada pelo satélite CBERS 4 em 2020 na região de Mogi das Cruzes - SP. . . . .	64
Figura 25 – Imagem de SR selecionada aleatoriamente. . . . .	67
Figura 26 – Malha aplicada sobre uma imagem de SR. . . . .	67
Figura 27 – Informações retiradas de um fragmento aleatório. . . . .	67
Figura 28 – Gráfico <i>boxplot</i> com os 10 melhores resultados dos métodos de extração de características para medida AUC. . . . .	72
Figura 29 – Ferramenta de automatização executando a rotina. . . . .	73
Figura 30 – AUC para os 10 melhores resultados obtidos pela RNA. . . . .	73

Figura 31 – AUC para os 10 melhores resultados obtidos pelo SVM. . . . .	74
Figura 32 – Gráfico <i>boxplot</i> com os 10 melhores resultados dos métodos de extração de características para medida AUC com imagens do satélite CBERS 4. . . . .	75
Figura 33 – Imagem original adquirida pelo satélite CBERS 4. . . . .	76
Figura 34 – Os resultados da técnica de classificação revelam limites quadrados quando comparados com a imagem original. As regiões verde e marrom representam regiões de florestas e ausência de florestas respectivamente. . . . .	76
Figura 35 – Figura 34 projetada sobre a Figura 33. . . . .	76
Figura 36 – Imagem original adquirida do CBERS 4 em 2017. . . . .	77
Figura 37 – Escala mais fina gerada pelo método multi-escala. . . . .	78
Figura 38 – Resultado do método multi-escala plotado sobre a figura original. . . . .	78
Figura 39 – Resultado do método <i>marker-controlled watershed-based</i> . . . . .	79
Figura 40 – Resultado do método <i>marker-controlled watershed-based</i> plotado sobre a figura original. . . . .	79
Figura 41 – Resultado do método SAVI classificada entre floresta (verde) e não floresta (marrom). . . . .	80
Figura 42 – Resultado do método SAVI em escala de cores. . . . .	80
Figura 43 – Resultado do método SAVI plotada sobre a imagem original. . . . .	80
Figura 44 – Resultado da técnica de AM classificada entre floresta (verde) e não floresta (marrom). . . . .	81
Figura 45 – Resultado da técnica de AM plotada sobre a imagem original. . . . .	81
Figura 46 – Resultado da estrutura colaborativa empregada classificada entre floresta (verde) e não floresta (marrom). . . . .	82
Figura 47 – Resultado da estrutura colaborativa empregada plotada sobre a imagem original. . . . .	82
Figura 48 – Indicação de erro zero devido as regiões estarem contidas uma nas outras. . . . .	83
Figura 49 – Imagem original em 2016. . . . .	85
Figura 50 – Imagem original em 2019. . . . .	85
Figura 51 – Resultado da abordagem colaborativa em 2016. . . . .	85
Figura 52 – Resultado da abordagem colaborativa em 2019. . . . .	85
Figura 53 – Desmatamento encontrado entre as imagens de 2016 e 2019 pela abordagem colaborativa. . . . .	86
Figura 54 – Desmatamento encontrado em 2018 pela Polícia Militar Ambiental do Estado de São Paulo. . . . .	86
Figura 55 – Imagem original em 2016. . . . .	87
Figura 56 – Imagem original em 2018. . . . .	87
Figura 57 – Resultado da abordagem colaborativa em 2016. . . . .	87
Figura 58 – Resultado da abordagem colaborativa em 2018. . . . .	87
Figura 59 – Identificação de áreas regeneradas entre a Figura 55 e a Figura 56 . . . . .	88



Figura 60 – Grade com órbitas e pontos para a cobertura do estado de SP com o satélite CBERS 4. . . . .	102
Figura 61 – Autuação da polícia projetada sobre uma imagem do <i>Google Earth</i> . . .	102
Figura 62 – Autuação da polícia projetada sobre a imagem do satélite CBERS 4. . .	102
Figura 63 – Autuação da polícia projetada sobre uma imagem do <i>Google Earth</i> . . .	103
Figura 64 – Autuação da polícia projetada sobre a imagem do satélite CBERS 4. . .	103
Figura 65 – Imagem original adquirida anteriormente a degradação. . . . .	105
Figura 66 – Imagem original adquirida após a degradação. . . . .	105
Figura 67 – Resultado do método multi-escala para a Figura 65. . . . .	106
Figura 68 – Resultado do método multi-escala para a Figura 66. . . . .	106
Figura 69 – Resultado do método <i>marker-controlled watershed-based</i> para a Figura 65.	107
Figura 70 – Resultado do método <i>marker-controlled watershed-based</i> para a Figura 66.	107
Figura 71 – Resultado da técnica de AM para a Figura 65. . . . .	107
Figura 72 – Resultado da técnica de AM para a Figura 66. . . . .	107
Figura 73 – Resultado do método SAVI para a Figura 65. . . . .	108
Figura 74 – Resultado do método SAVI para a Figura 66. . . . .	108
Figura 75 – Resultado da abordagem colaborativa para a Figura 65. . . . .	109
Figura 76 – Resultado da abordagem colaborativa para a Figura 66. . . . .	109
Figura 77 – Autuação delimitada manualmente com o auxílio de GPS pela Polícia Militar Ambiental. . . . .	109
Figura 78 – Sugestão de área degradada identificada pela abordagem colaborativa. .	109
Figura 79 – Imagem original adquirida anteriormente a degradação. . . . .	110
Figura 80 – Imagem original adquirida após a degradação. . . . .	110
Figura 81 – Resultado do método multi-escala para a Figura 79. . . . .	111
Figura 82 – Resultado do método multi-escala para a Figura 80. . . . .	111
Figura 83 – Resultado do método <i>marker-controlled watershed-based</i> para a Figura 79.	111
Figura 84 – Resultado do método <i>marker-controlled watershed-based</i> para a Figura 80.	111
Figura 85 – Resultado da técnica de AM para a Figura 79. . . . .	112
Figura 86 – Resultado da técnica de AM para a Figura 80. . . . .	112
Figura 87 – Resultado do método SAVI para a Figura 79. . . . .	112
Figura 88 – Resultado do método SAVI para a Figura 80. . . . .	112
Figura 89 – Resultado da abordagem colaborativa para a Figura 79. . . . .	113
Figura 90 – Resultado da abordagem colaborativa para a Figura 80. . . . .	113
Figura 91 – Autuação delimitada manualmente com o auxílio de GPS pela Polícia Militar Ambiental. . . . .	114
Figura 92 – Sugestão de área degradada identificada pela abordagem colaborativa. .	114



# Lista de tabelas

Tabela 1 – Matriz de confusão para classificação binária. . . . .	45
Tabela 2 – Informações referente aos sensores remotos estudados. . . . .	65
Tabela 3 – Representação dos métodos de extração de características combinados apresentados na Figura 28. . . . .	72
Tabela 4 – Representação dos métodos de extração de características combinados apresentados na Figura 30. . . . .	73
Tabela 5 – Representação dos métodos de extração de características combinados apresentados na Figura 31. . . . .	74
Tabela 6 – Representação dos métodos de extração de características combinados apresentados na Figura 32. . . . .	75
Tabela 7 – Métricas de LCE, GCE e Kappa Index para cada método de segmentação aplicado. . . . .	82
Tabela 8 – Métricas LCE, GCE e Kappa Index para cada método de segmentação aplicado. . . . .	84
Tabela 9 – Métricas de LCE, GCE e Kappa Index para cada método de segmentação aplicado . . . . .	106
Tabela 10 – Métricas de LCE, GCE e Kappa Index para cada método de segmentação aplicado . . . . .	110



# Lista de abreviaturas e siglas

AM	Aprendizado de Máquina
AUC	<i>Area under the ROC Curve</i>
CBERS	<i>China-Brazil Earth Resources Satellite</i>
CRF	<i>Conditional Random Field</i>
DETER	Detecção de Desmatamento em Tempo Real
EUA	Estados Unidos da América
ERTS	<i>Earth Resources Technology Satellite</i>
GCE	<i>Global Consistency Error</i>
GPS	<i>Global Positioning System</i>
HOG	<i>Histogram of Oriented Gradients</i>
HTD	<i>Homogeneous Texture Descriptor</i>
IBAMA	Instituto Brasileiro de Meio Ambiente e Recursos Naturais Renováveis
INCRA	Instituto Nacional de Colonização e Reforma Agrária
INPE	Instituto Nacional de Pesquisas Espaciais
JSON	<i>JavaScript Object Notation</i>
kNN	<i>k-Nearest Neighbor</i>
LAS	<i>Local Activity Spectrum</i>
LCE	<i>Local Consistency Error</i>
LUCC	<i>Land-Use/Land-Cover Change</i>
LU/LC	<i>Land-Use/Land-Cover Change</i>
LULC	<i>Land-Use/Land-Cover Change</i>
LCLU	<i>Land Cover Land Use Change</i>
NBR	<i>Normalized Burn Ratio</i>

NDVI	<i>Normalized Difference Vegetation Index</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
PRODES	Projeto de Monitoramento do Desmatamento da Amazônia
QCCH	<i>Quantized Compound Change Histogram</i>
RBF	<i>Radial Basis Function</i>
RF	<i>Random Forest</i>
RNA	Rede Neural Artificial
SASI	<i>Statistical Analysis of Structural Information</i>
SAVI	<i>Soil-Adjusted Vegetation Index</i>
SR	Sensoriamento Remoto
SICAR	Sistema Nacional de Cadastro Ambiental Rural
SRC	<i>Sparse Representation-based Classification</i>
SVM	<i>Support Vector Machine</i>
TCW	<i>Tasseled Cap Wetness</i>
USGS	<i>United States Geological Survey</i>

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>23</b>
1.1	Objetivos	27
1.2	Organização do texto	27
<b>2</b>	<b>TRABALHOS RELACIONADOS</b>	<b>29</b>
2.1	<i>Land-Use/Land-Cover Change</i>	29
2.1.1	Segmentação	29
2.1.2	Aprendizado de máquina	30
2.2	Desmatamento	31
2.3	Segmentação híbrida	33
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>35</b>
3.1	Sensoriamento Remoto	35
3.2	Segmentação	36
3.2.1	<i>Marker-controlled watershed-based segmentation</i>	37
3.2.2	Segmentação multi-escala	38
3.2.3	Segmentação híbrida	39
3.3	Índices de vegetação	40
3.4	Aprendizado de máquina	42
3.4.1	Métodos de extração de características	42
3.4.2	<i>Augmentation</i>	43
3.4.3	Técnicas de classificação	44
3.5	Métodos de avaliação	45
3.5.1	Classificação	45
3.5.2	Segmentação	46
<b>4</b>	<b>ABORDAGEM PROPOSTA</b>	<b>49</b>
4.1	Aquisição e pré-processamento de imagens	50
4.2	Segmentação	53
4.3	Abordagem colaborativa	55
4.4	Comparação de imagens	57
<b>5</b>	<b>EXPERIMENTOS</b>	<b>61</b>
5.1	Área de estudo e dados de referência	61
5.2	Extração de características	65
5.3	Classificação	66

5.3.1	Treinamento . . . . .	66
5.3.2	Algoritmos . . . . .	68
<b>5.4</b>	<b>Segmentação . . . . .</b>	<b>69</b>
<b>6</b>	<b>RESULTADOS . . . . .</b>	<b>71</b>
<b>6.1</b>	<b>Classificação . . . . .</b>	<b>71</b>
6.1.1	RapidEye . . . . .	71
6.1.2	CBERS 4 . . . . .	74
<b>6.2</b>	<b>Segmentação . . . . .</b>	<b>76</b>
6.2.1	Análise qualitativa . . . . .	77
6.2.2	Análise quantitativa . . . . .	82
<b>6.3</b>	<b>Desmatamento . . . . .</b>	<b>84</b>
<b>6.4</b>	<b>Regeneração . . . . .</b>	<b>86</b>
	<b>Conclusão . . . . .</b>	<b>89</b>
	<b>Referências . . . . .</b>	<b>93</b>
	<b>APÊNDICE A – PROCESSAMENTO DE IMAGENS . . . . .</b>	<b>101</b>
	<b>APÊNDICE B – RESULTADOS DE SEGMENTAÇÃO . . . . .</b>	<b>105</b>



# 1 INTRODUÇÃO

A importância das florestas perpassa pelo equilíbrio biológico, garantia da biodiversidade e demais aspectos ambientais e econômicos (BOYD; DANSON, 2005). No entanto atividades agrícolas, exploração excessiva dos recursos naturais, incêndios e urbanização, têm contribuído para as elevadas taxas de desmatamento apontadas ao redor do mundo e assim causam numerosas consequências como erosão do solo, nível de carbono desequilibrado, diminuição da biodiversidade, redução da fertilidade do solo, escassez de água, enchentes e desertificação (KLINK; MACHADO, 2005; ROCHA et al., 2011; ZEGEYE, 2017).

Devido à sua importância global, a floresta amazônica é a que desperta maior interesse entre os pesquisadores. Contudo, no estado de São Paulo, os biomas do cerrado brasileiro (KLINK; MACHADO, 2005) e da mata atlântica (TABARELLI et al., 2005) são considerados *hotspots* mundiais de biodiversidade, pois abrigam entre 7.000 e 8.000 espécies endêmicas e possuem alto grau de ameaça. Estes biomas compreendiam originalmente uma área de cerca de 3.360.000 km<sup>2</sup>, ocupando 21 estados brasileiros (SANO; JESUS; BEZERRA, 2001; MANTOVANI et al., 2018). Entretanto, não diferente de outras florestas, atividades de extração de madeira, culturas agrícolas e agropecuária têm impactado na diminuição da mata atlântica e da região do cerrado, que apresentou apenas 7% de sua cobertura original (TABARELLI et al., 2005) e 45% de sua área preservada (KLINK; MACHADO, 2005) respectivamente.

A conscientização a respeito dos malefícios do desmatamento das regiões afetadas influenciou a entrada do Brasil nos acordos de Paris, *Bonn Challenge* e a provisão do pacto pela restauração da mata atlântica, pelo qual foi estabelecido o compromisso de reflorestamento de 15 milhões de hectares até 2050 (CROUZEILLES et al., 2019). Estima-se que até o fim de 2020 cerca de 1,35 a 1,48 milhões de hectares estejam em processo de restauração ou completamente restabelecidos. Políticas governamentais, uso de sistemas de monitoramento das florestas e reduzida produtividade dos pastos são as razões para os dados promissores alcançados (CROUZEILLES et al., 2019).

Com o propósito de coibir o desmatamento ilegal no Brasil, foi instituído a lei nº 9.605, de 12 de Fevereiro de 1998 que sentenciou diretrizes a quem cometer crimes ambientais (GERAIS, 1998). No decreto são previstas multas a quem destrói ou danifica florestas brasileiras, que são agravadas a cada hectare desmatado caso a floresta seja de vegetação natural ou nativa plantada e, em ambos os casos, associada à fase de regeneração do bioma (GERAIS, 1998).

Para que a Lei seja aplicada, é necessário a identificação das regiões degradadas, a

qual geralmente é realizada por especialistas, o que demanda tempo, gera dificuldades de reconhecimento e está sujeita a análises subjetivas (BOYD; DANSON, 2005). O avanço de tecnologias para a captura e processamento de imagens de sensoriamento remoto (SR) e de outras técnicas computacionais, motivada pelo incremento na destruição das florestas, permitiu o desenvolvimento de sistemas capazes de auxiliar na identificação de áreas potencialmente desmatadas (ACHARD et al., 2014; ROCHA et al., 2011).

*ForestWatchers* é um dos sistemas com foco na redução do desmatamento global. Trata-se de um projeto voluntário que recebe o apoio de cidadãos que realizam análises manuais de imagens de SR para auxiliar na composição de um mapa mundial de degradação de florestas atualizado (ARCANJO et al., 2016).


Direcionado para a floresta amazônica, o Projeto de Monitoramento do Desmatamento da Amazônia (PRODES) e o sistema de Detecção de Desmatamento em Tempo Real (DETER) (ACHARD; HANSEN, 2016) são exemplos de projetos desenvolvidos pelo Instituto Nacional de Pesquisas Espaciais (INPE) para análise de desmatamento. Esses projetos têm objetivos diferentes: fornecer resultados anuais de desmatamento e monitorar a região, apontando as possibilidades de desmatamento para o Instituto Brasileiro de Meio Ambiente e Recursos Naturais Renováveis (IBAMA), respectivamente (DALLAQUA; FARIA; FAZENDA, 2018).

Objetivando outras áreas do território brasileiro, o projeto MapBiomass é, segundo Crouzeilles et al. (2019), “uma iniciativa colaborativa que envolve organizações não-governamentais, empresas privadas e organizações de pesquisa para monitorar anualmente as mudanças no uso da terra em todas as regiões biogeográficas brasileiras”. A plataforma desenvolvida pelo MapBiomass acessa dados de outros estudos e cruza com informações advindas de órgãos brasileiros, como o Instituto Nacional de Colonização e Reforma Agrária (INCRA) e o Sistema Nacional de Cadastro Ambiental Rural (SICAR) para determinar se o desmatamento foi ilegal ou consentido pelo governo brasileiro.

Devido a esses estudos de monitoramento ambiental estarem no domínio de processamento de imagem de SR, estes são fundamentados em sete etapas principais (Figura 1). Primeiro, o sensor remoto deve ser selecionado e suas imagens adquiridas. O que remete ao segundo passo, onde as correções atmosféricas e geométricas poderão ser aplicadas. A seguir, a imagem deve ser agrupada em conjuntos de *pixels*, de acordo com um critério de homogeneidade (processo de segmentação). A quarta etapa, vetorização, é composta pela descrição das informações do segmento, como textura ou forma, em um vetor de características, os quais devem ser rotulados ou classificados com base no objetivo do estudo num processo denominado classificação. A escolha do segmentador e do extrator de característica dependem do objetivo da análise das imagens e influenciam diretamente nos resultados obtidos na etapa de classificação (KEMKER; SALVAGGIO; KANAN, 2018; SUN; WANG, 2018). Finalmente, o último passo é a avaliação dos resultados

(TROYA-GALVIS; GANÇARSKI; BERTI-ÉQUILLE, 2018a).

Figura 1: Fluxograma de processamento de imagens de SR.



Fonte: Adaptado de Troya-Galvis, Gançarski e Berti-Équille (2018a).

Nesse escopo, a segmentação é uma etapa crucial do processamento de imagens com foco em análise de mudança de solo (GU et al., 2018) e portanto, vários métodos de segmentação foram propostos para esse fim. De acordo com Schiewe (2002), esses métodos podem ser agrupados em quatro categorias: baseado em pontos (*clustering*) (WANG et al., 2009; YUAN; WANG; LI, 2014), detecção de borda (rastreamento de limite) (JUDAH; HU; WANG, 2014), baseado em região (*watershed*, segmentação multiescala) (KARANTZALOS; ARGIALAS, 2009; GUIGUES; COCQUEREZ; MEN, 2006) e combinados (WANG et al., 2018). Cada categoria tem suas vantagens e desvantagens, por exemplo, os métodos de segmentação multi-escala criam vários níveis de segmentação, ou seja, existem várias segmentações resultantes desse método para a mesma imagem avaliada, desde uma segmentação super-segmentada (*over-segmented*) até uma sub-segmentada (*under-segmented*) (GU et al., 2018; GUIGUES; COCQUEREZ; MEN, 2006). Portanto, ao tentar selecionar o melhor resultado da segmentação para um determinado estudo por meio de inferência visual ou determinar uma escala fixa para esse fim, há a possibilidade de seleção de uma escala inadequada, levando a um resultado de má qualidade (SANTOS et al., 2013). Uma solução para esse problema foi proposta por Santos et al. (2013), que tenta selecionar de forma automática as melhores escalas.

Atualmente as técnicas de aprendizado de máquina (AM) tem sido muito utilizadas no processo de segmentação de imagens (MICHEL; YOUSSEFI; GRIZONNET, 2015; SUN; WANG, 2018; KEMKER; SALVAGGIO; KANAN, 2018). Normalmente, ao invés de *pixels*, as técnicas de aprendizado são capazes de identificar padrões complexos em imagens de alta resolução por meio de características extraídas usando diferentes descritores de imagens (SANTOS et al., 2013). Classificação de culturas, desmatamento, uso e cobertura da terra são exemplos de tarefas nas quais as técnicas de AM alcançaram resultados significativos através de técnicas supervisionadas (classificação) e não-supervisionadas (agrupamento) (HAGENSIEKER, 2018). As técnicas supervisionadas possuem a desvantagem de necessitar de um conhecimento prévio provido por um especialista em um número razoável de amostras

de todas as classes do problema. Porém com a aplicação de uma técnica não-supervisionada, o prejuízo estará na falta de classificação da região de interesse.

No aspecto do estudo de SR, recentemente a técnica de comitê (*ensemble*), como a classificação por votação, pelo qual um conjunto de métodos são criados e combinados entre si para produzir melhores resultados, é explorada para detectar mudanças de vegetação (HISLOP et al., 2019). Nessa técnica de classificação por votação, são realizadas múltiplas segmentações, estabelecendo rótulos para cada região originada e, conseqüentemente, para cada *pixel*. Esses rótulos são contabilizados como votos em uma eleição para cada ponto da imagem. Finalmente, a figura segmentada é criada pela média dos votos através de um modelo probabilístico.

Zhu (2017) revisou mais de cinquenta estudos de métodos de segmentação de imagens para detectar áreas desmatadas. Os índices de vegetação são amplamente explorados devido à forte correlação entre a biomassa e o dossel através da reflexão da vegetação no infravermelho próximo. Esses métodos são frequentemente avaliados para sugerir áreas desmatadas, uma vez que o resultado do método indica se a vegetação é saudável ou não por meio de uma equação aplicada para cada *pixel* da imagem (SCHULTZ et al., 2016). Sendo assim, os índices de vegetação juntamente com o uso de um valor limiar para distinção entre presença e ausência de vegetação, tornam-se valiosos métodos baseados em região.

Nesse contexto, abordagens colaborativas de segmentação apontam melhores resultados, uma vez que algumas dessas limitações são superadas pela combinação de diferentes métodos (WANG et al., 2018). A maioria dessas abordagens é fundamentada em dois grupos de segmentação: baseada em borda e por região. O primeiro traça os limites da imagem e encontra os detalhes do objeto, enquanto o segundo ajusta os limites e mescla os segmentos semelhantes através dos *pixels* internos e das bordas da imagem (YANG; HE; CASPERSEN, 2017; HOSSAIN; CHEN, 2019).

Apesar do sucesso dos sistemas computacionais para monitoramento e identificação de desmatamento por meio de imagens de SR, suas usabilidades nem sempre são satisfatórias. Por esse motivo, órgãos responsáveis pelo monitoramento e autuações de áreas desmatadas, como a Polícia Militar Ambiental, realiza esse processo manualmente, analisando regiões por meio de imagens de SR atuais e comparando-as com imagens antigas. Além disso, não é conhecido outro projeto que busque identificar áreas degradadas com foco em território brasileiro, cujo os resultados foram validados com autuações de infrações ambientais encontradas pelas Polícias Militares Ambientais Estaduais brasileiras e demarcados com o uso de tecnologias de *Global Positioning System* (GPS).

Adicionalmente, outras alternativas no processamento e classificação das imagens de SR precisam ser melhor investigadas (WANG et al., 2018; HOSSAIN; CHEN, 2019), por exemplo, a investigação de algoritmos híbridos de segmentação em que um algoritmo

pode suprir a limitação do outro ainda são incipientes (WANG et al., 2018) e portanto, esse trabalho visa responder as seguintes questões de pesquisa:

- Imagens de SR com resolução espacial superior a 30m permite uma melhor segmentação da imagem entre vegetação e solo exposto?
- Uma abordagem colaborativa de diferentes métodos de segmentação de imagens de SR possibilita resultados melhor delineados?

## 1.1 Objetivos

O objetivo geral deste projeto de pesquisa é desenvolver e avaliar uma abordagem capaz de identificar regiões de vegetação degradadas por meio do emprego de técnicas de segmentação em imagens de SR que possa auxiliar a Polícia Militar Ambiental do Estado de São Paulo na tarefa de fiscalização.

Para atingir o objetivo geral, são elencados os específicos:

- prover um banco de imagens parcial de SR do estado de SP com resolução acima de 15m;
- avaliar técnicas de AM correlatas com processo de classificação de áreas com florestas ou solos expostos para diferentes métodos de extração de características;
- avaliar os métodos de segmentação de áreas degradadas e regeneradas através de imagens de SR;
- propor e desenvolver uma abordagem colaborativa para identificação de regiões de interesse;
- confrontar os resultados com dados de fiscalização auxiliados pelo uso GPS.

## 1.2 Organização do texto

A presente dissertação está estruturada como segue. No [Capítulo 2](#) são apresentados os trabalhos relacionados. A fundamentação teórica está presente no [Capítulo 3](#). A abordagem de segmentação colaborativa proposta nesse estudo é apresentada no [Capítulo 4](#). No [Capítulo 5](#), são detalhados os materiais e métodos utilizados na realização de experimentos a fim de avaliar a abordagem proposta. Os resultados estão dispostos no [Capítulo 6](#). Por fim, as considerações finais e perspectivas são apresentadas na Conclusão.



## 2 TRABALHOS RELACIONADOS

Na literatura é possível encontrar diversos trabalhos que utilizam imagens de SR para análises relacionadas ao solo, como pesquisas com o objetivo de detectar desmatamento. O enfoque do presente estudo está nessas pesquisas, bem como nas diferentes técnicas de segmentação que auxiliam esse propósito. Portanto, neste capítulo são apresentados os trabalhos relacionados à segmentação de imagens de SR, principalmente aqueles com o foco de detectar áreas degradadas.

### 2.1 *Land-Use/Land-Cover Change*

O ramo da literatura que avalia as mudanças no solo através de imagens de SR aparece com diferentes nomes e acrônimos, como *Land-Use/Land-Cover Change* (LULC, LUCC ou LU/LC) (SONG; DENG, 2017; TOLESSA; SENBETA; KIDANE, 2017; ZOPE; ELDHO; JOTHIPRAKASH, 2016) e *Land Cover and Land Use Change* (LCLU) (SOUZA-FILHO et al., 2015). Trata-se de uma abordagem na qual é feito o reconhecimento dos tipos de cobertura presentes no solo nas imagens de SR para realizar o monitoramento e detecção das mudanças. Os progressos realizados nas pesquisas baseadas em LCLU precisam ser considerados nos estudos de detecção de desmatamento em razão da semelhança no processo de comparação das imagens para reconhecimento das modificações.

#### 2.1.1 Segmentação

O processo de segmentação é realizado com o objetivo de dividir as imagens em objetos com valores semânticos para que elas possam ser classificadas posteriormente. No caráter de SR, gerar a segmentação de uma imagem em apenas uma escala possivelmente será insuficiente, ou seja, a janela de percepção em que a segmentação ocorrerá pode aumentar ou reduzir a quantidade de detalhes no resultado (BLASCHKE, 2010). Nesse âmbito, Trias-Sanz e Boldo (2005) aplicaram um método de segmentação multi-escala baseado no critério de energia de Mumford-Shah para delinear as bordas de imagens aéreas de alta resolução na França. Após o processo de segmentação, as regiões classificadas alcançaram resultados superiores a 95% de acurácia.

A desvantagem gerada pela segmentação multi-escala, se dá devido a necessidade de saber qual escala será utilizada (BLASCHKE, 2010). Para tratar esse problema, Santos et al. (2013) desenvolveram quatro linhas de pesquisas com o objetivo de melhor representar a imagem e extrair suas características. A pesquisa emprega a combinação de técnicas de classificação com resultados do método de segmentação multi-escala para selecionar qual a

escala mais adequada para análise de imagens com áreas de plantio de café, urbanas e pastos. Contudo o estudo conclui que o emprego de mais de uma escala de segmentação alcança melhores resultados.

Outra solução para lidar com o problema das várias segmentações geradas pelo método multi-escala foi criada por [Gaetano et al. \(2015\)](#). O trabalho propõe uma segmentação única através do método *watershed* realizando o delineamento das bordas em escalas grossas e a adição de marcadores para auxiliar na preservação dos detalhes em escalas mais finas. [Gaetano et al. \(2015\)](#) avaliou imagens do satélite IKONOS com resolução espacial de 1m no estado da Califórnia, Estados Unidos da América (EUA) para segmentar seis classes existentes no conjunto de dados e alcançou resultados promissores.

Ainda assim, os métodos apresentados por [Gaetano et al. \(2015\)](#) e [Santos et al. \(2013\)](#) são ineficientes quando aplicados a imagens que contém objetos com propriedades semelhantes, por exemplo geométricas, texturas ou espectrais. Portanto uma possível solução seria o uso de técnicas de AM para encontrar as características e os valores semânticos complexos presentes na imagem ([CASTELLUCCIO et al., 2015](#)).

### 2.1.2 Aprendizado de máquina

Os resultados das técnicas de AM utilizadas para classificação das coberturas presentes nas imagens de SR são influenciados pelos métodos de extração de características empregados. Esses métodos descrevem as imagens com base na sua textura, cor, formas, entre outros aspectos, gerando um vetor de características, que posteriormente pode ser usado para o treinamento dos modelos de AM ([Subseção 3.4.1](#)).

Nesse cenário, [Penatti, Valle e Torres \(2012\)](#) realizaram uma pesquisa comparando diferentes métodos, como baseados em cores, texturas e aprendizagem profunda. Nesse trabalho foram utilizados dois conjuntos de imagens de SR, sendo um deles referente a áreas de plantio de café e outro imagens aéreas de alta resolução. Os resultados indicaram que para as imagens das regiões de café, os métodos de extração baseados em cores e texturas obtiveram resultados superiores à aprendizagem profunda. Outra conclusão foi que a simples combinação dos vetores resultantes de cada método supera os resultados individuais.

Após a escolha dos métodos de extração de características, a etapa de classificação pode ser realizada. Para executar essa tarefa, diferentes técnicas de AM podem ser empregadas. Sendo assim, [Souza-Filho et al. \(2015\)](#) concluíram usando métodos de processamento de imagem, classificação baseada em objetos e interpretação manual que cerca de 1,7 milhões de hectares de florestas foram transformados em pastos ao longo da bacia hidrográfica do rio Itacaiúnas entre 1984 e 2013.

Em outro estudo, [Nguyen, Doan e Radeloff \(2018\)](#) realizaram uma série de experi-



mentos para classificar as imagens do satélite Landsat 8 de uma região no Vietnã em dez diferentes classes, alcançando resultados superiores a 90% de acurácia. A técnica empregada foi a *random forest* (RF) e teve como objetivo definir os melhores hiperparâmetros para pesquisas com esse propósito (número de árvores e número de variáveis usadas para dividir cada nó).

Outra técnica empregada por [Haapanen et al. \(2004\)](#), foi o *k*-Vizinhos Mais Próximos (do inglês, *k-Nearest Neighbor* - kNN) baseado na função Euclidiana, em imagens extraídas pelo satélite Landsat 7 ETM+ no ano de 2000 em uma região de aproximadamente 30 mil km<sup>2</sup> no nordeste de Minnesota, EUA, para estratificar e estimar áreas de florestas, água e outras áreas.

Independente do método de classificação usado, um problema conhecido relacionado à análise de imagens de SR são os cenários abertos. O treinamento de um método de AM geralmente é feito sob a premissa de que todas as classes são conhecidas, o que é controverso em um cenário aberto. Contudo, trabalhos recentes mostraram que estratégias de classificação multi-classes, como a um-contra-todos (*one-vs-all*), utilizadas principalmente por máquinas de vetores de suporte (do inglês, *Support Vector Machine* - SVM), podem ser adotadas para minimizar alguns problemas encontrados nesses cenários ([JÚNIOR, 2018](#)).

## 2.2 Desmatamento

Os trabalhos apresentados na [Seção 2.1](#) não estão diretamente ligados ao desmatamento. Entretanto, todos corroboram para a construção de algoritmos de segmentação que podem ser empregados para delimitar regiões de vegetação e regiões de solo exposto.

Os trabalhos referência na literatura sobre análise de imagens para sugestões de áreas desmatadas, geralmente utilizam dados dos satélites da série Landsat ([HETHCOAT et al., 2019](#)). Segundo [Banskota et al. \(2014\)](#), isso é explicado em três vertentes: i) o Landsat contém um histórico de 40 anos de imagens disponíveis; ii) suas imagens possuem 30m de resolução espacial e 16 dias de resolução temporal, o que é considerado relativamente baixo; e iii) todas as imagens estão no repositório *United States Geological Survey* (USGS) gratuitamente e prontas para análise. Entretanto, satélites como o Pleiades, estão se tornando modelos nos estudos de SR devido as altas resolução espaciais que possibilitam maiores acurácias ([GAETANO et al., 2015](#)).

Segundo [Hammer, Kraft e Wheeler \(2014\)](#), existem dois métodos de busca por desmatamento em imagens de SR: diferença transversal (*cross-sectional differencing*) e análise temporal. A primeira obtém bons resultados com imagens de altas resoluções, entretanto é impactada pela baixa resolução temporal e frequência de nuvens. A segunda, analisa todos os *pixels* da imagem comparando o espectro com dados capturados anteriormente

(KENNEDY; COHEN; SCHROEDER, 2007).

Atualmente, diversos trabalhos aplicam o método de análise temporal para encontrar áreas desmatadas. Othman et al. (2018) aplicaram uma abordagem baseada em índice de vegetação por diferença normalizada (do inglês, *normalized difference vegetation index - NDVI*) em imagens capturadas pelo satélite *Moderate Resolution Imaging Spectroradiometer* (MODIS) para monitorar o desmatamento na Malásia. O estudo alcançou resultados entre 70% e 90% de acurácia, dependendo das imagens e do ano analisado, e concluiu que 96% da floresta encontrada em 2002 foi reduzida para 87% em 2015.

Em outra abordagem, Gomez et al. (2015) segmentaram com o auxílio do *software* eCognition e classificaram imagens Landsat da região amazônica entre 1975 até 2014 em 6 diferentes classes (cobertura de árvores, mosaico de cobertura de árvores, outros terrenos arborizados, outros terrenos, água e sem informação) para quantificar a taxa de desmatamento ao longo do tempo. A pesquisa concluiu que a região estudada teve uma redução média de 0,71% de cobertura vegetal anual, durante 39 anos, ou seja, comparando as imagens de 1975 e 2014, a redução vegetal foi de 24,2%.

Alguns estudos de sistemas de monitoramento de desmatamento e alertas em tempo real são utilizados em cenários reais auxiliando órgãos governamentais a combater as práticas ilegais de desflorestação (ACHARD et al., 2014; HAMMER; KRAFT; WHEELER, 2014). Um desses sistemas (PRODES), foi desenvolvido pelo INPE para identificar possíveis desmatamentos rasos, ou seja, regiões completamente desmatadas, em tempo real por meio de satélites do tipo Landsat em uma área de aproximadamente 59% do território brasileiro. Outros projetos similares ao PRODES que podem ser listados são: DETER, Global ForestWatcher e FORMA.

Em geral, as técnicas e algoritmos estudados com objetivo de identificar desmatamento permitem resultados alcançados superiores a 90%, com imagens de satélites fornecidas gratuitamente (HETHCOAT et al., 2019). Entretanto a detecção ocorre normalmente em mudanças abruptas nas imagens, ou seja, essas pesquisas apresentam resultados inferiores quando analisam áreas onde a degradação não é total, o que pode ser atribuído à resolução de 30m apresentada pelos satélites Landsat. Hethcoat et al. (2019) construíram um modelo de AM que obteve aproximadamente 90% de taxa de detecção de desmatamento em cenários onde o corte da madeira ainda estava incompleto.

Recentemente, as arquiteturas de aprendizagem profunda estão sendo aplicadas em imagens de SR com viés de segmentar e detectar desmatamento alcançando resultados promissores (WYNIAWSKYJ et al., 2019). Rakshit, Debnath e Mondal (2018) aplicaram essa técnica para encontrar áreas desmatadas na região da Amazônia, no Brasil. O projeto aplicou uma classificação supervisionada entre janeiro de 2016 e fevereiro de 2017, cujo conjunto de imagens de alta resolução conhecido foi classificado por pessoas remuneradas e voluntárias em uma plataforma chamada *Crowd Flower*.

## 2.3 Segmentação híbrida

Em virtude das limitações apresentadas pelos diferentes métodos de segmentação, uma nova tendência para essa área de pesquisa são os métodos híbridos (HOSSAIN; CHEN, 2019). Mueller, Segl e Kaufmann (2004) desenvolveram uma segmentação em duas etapas, sendo a primeira responsável por delinear os objetos e a segunda por agrupá-los baseados em características comuns. O método apresentou vantagens ao extrair informações sobre campos de agriculturas e resultados superiores a quase todos os métodos comparados. Zhang et al. (2014) propuseram um *framework* híbrido que foi avaliado com diferentes tipos de imagens e paisagens de SR. Durante a análise, o autor evidencia o resultado promissor ao comparar o novo método com três métodos de segmentação individuais.

Frequentemente, os métodos híbridos de segmentação incluem a segmentação baseada em bordas (*edge-based*) e outra baseada em regiões (*region-based*), as quais são agrupadas seguindo um critério de heterogeneidade entre os segmentos adjacentes. Wang et al. (2018) demonstraram superioridade nos resultados ao avaliar imagens de SR com paisagens urbanas, rurais e florestas da região de Beijing (China), utilizando critérios de heterogeneidade entre os segmentos adjacentes e homogeneidade entre os elementos da imagem.

Diferentemente da abordagem padrão de segmentação híbrida, Troya-Galvis, Gancarski e Berti-Équille (2018a) construíram um *framework* colaborativo que incluía uma técnica de classificação e um método de segmentação para analisar as imagens do satélite Pleiades, cuja resolução espacial é de 0,5m, na região nordeste da França com o objetivo de segmentar a vegetação presente na imagem. O desenvolvimento do método inicia-se de uma sobre-segmentação e finaliza com a união dos segmentos semelhantes gerados. Os resultados foram promissores, representados por uma melhor acurácia na obtenção dos segmentos de vegetação.

A união de métodos de segmentação e técnicas de classificação, podem ser atribuídas a uma estrutura de votação (*ensemble*). Tarabalka, Benediktsson e Chamussot (2009) propuseram um método híbrido composto por um método de segmentação baseado em *clusters* e um método de classificação empregando um esquema de votos para decidir a classificação de cada segmento.

As diferentes técnicas e a variação de parâmetros dentro da mesma técnica para detecção de mudanças no solo, tais como desmatamento, apresentam resultados instáveis. Para lidar com isso, Hislop et al. (2019) abordaram duas técnicas de detecção de mudanças (baseado em segmentação e em limites estatísticos) acoplados com três índices de vegetação. Com o resultado das seis combinações, o autor investigou o emprego da técnica de *ensemble* para gerar o resultado baseado nos diferentes comportamentos. O estudo foi avaliado com imagens de floresta na Austrália capturadas por satélite do tipo Landsat e alcançou 7% de

*overall error rate.*

As diferentes técnicas apresentadas pela literatura para lidar com a tarefa de delinear e classificar regiões de florestas e de solo exposto e assim encontrando áreas de desmatamento, possuem vantagens e desvantagens. Por se tratar de uma abordagem híbrida entre segmentador, técnica de *ensemble* e índices de vegetação, o trabalho de [Hislop et al. \(2019\)](#) embasa a abordagem apresentada nessa dissertação. Contudo, o trabalho aplica as abordagens de maneira interdependentes conforme descrito na [Subseção 3.2.3](#), ou seja, os métodos de segmentação são aplicados baseados nos índices de vegetação e seus resultados são fonte para a técnica de *ensemble* que dará origem ao resultado final. Sob esse contexto, a união das técnicas de AM, métodos de segmentação e índices de vegetação de forma independente se torna uma abordagem colaborativa promissora, que pode alcançar melhores resultados.

## 3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os conceitos, métodos e técnicas utilizados para o desenvolvimento e avaliação da abordagem colaborativa proposta neste trabalho. Ele inclui os conceitos de SR (Seção 3.1), os métodos de segmentação (Seção 3.2), os índices de vegetação (Seção 3.3), técnicas de AM (Seção 3.4) e medidas de avaliação (Seção 3.5).

### 3.1 Sensoriamento Remoto

Em 23 de julho de 1972, foi lançado o primeiro satélite Landsat integrante de um Programa de Satélites de Tecnologia de Recursos Terrestres (*Earth Resources Technology Satellite* - ERTS). Esse programa contribuiu para o surgimento de novas estruturas e técnicas de processamento de imagens em virtude dos dados serem complexos e diferirem do processamento realizado em imagens não provindas de SR (SANTOS et al., 2013).

A escolha do sensor que fornecerá as imagens utilizadas na análise do solo é o primeiro passo para iniciar um estudo nessa área (XIE; SHA; YU, 2008). Segundo Xie, Sha e Yu (2008), o processo para determinar qual satélite será utilizado contém quatro diretrizes: os problemas para interpretar as imagens, os seus custos, as condições climáticas e o objetivo do estudo. Para auxiliar esse processo, cada sensor apresenta quatro informações básicas que o caracterizam: resolução espacial, temporal, radiométrica e espectral (STEFFEN; SOLAR, 2011).

A resolução espacial especifica o nível de detalhamento dos objetos na superfície terrestre (STEFFEN; SOLAR, 2011). Em outras palavras, a equivalência em metros representada pelos *pixels*. Quanto a resolução espacial, a imagem de SR pode ser classificada em: baixa resolução (*pixels* com amostra de 30m ou mais), média resolução (*pixels* com amostra entre 2m e 30m), alta resolução (*pixels* com amostra entre 0,5m e 2m) e altíssima resolução (*pixels* com amostra abaixo de 0,5m) (NAVULUR, 2006; WILLIS, 2015). As imagens geradas pelo satélite Landsat possuem resolução de 30m (MILLETTE et al., 1995), portanto, de baixa resolução e são consideradas padrões para uso em projetos de análise de mudanças e cobertura do solo (GÓMEZ; WHITE; WULDER, 2016; WILLIS, 2015).

Os satélites estão em movimento ao redor da Terra e, em sua maioria, transitando próximos aos polos. Esse deslocamento, combinado com o movimento de rotação do planeta, dá origem ao termo resolução temporal ou a frequência na qual o sensor revisita uma determinada região. Os satélites da série Landsat possuem resolução de 16 dias, fato que pode influenciar um estudo de SR caso exista a necessidade de análise diária das imagens

([STEFFEN; SOLAR, 2011](#)).

A resolução espectral aborda as informações referentes ao espectro eletromagnético que o satélite é capaz de capturar, o que exerce influência direta ao estudo em que as imagens são submetidas. Isso ocorre, pois algumas bandas são indicadas para determinadas análises ([STEFFEN; SOLAR, 2011](#)). Um exemplo é o caso do infravermelho próximo que é apontado para estudos relacionados à vegetação. Portanto, a resolução espectral é outro ponto a ser considerado na decisão do satélite ([SCHULTZ et al., 2016](#)).

A última resolução, a radiométrica, representa “a capacidade do sensor de diferenciar níveis de energia” ([BARBOSA, 1998](#)). O satélite Landsat 8 possui uma resolução radiométrica de 16 bits, característica que torna o tamanho computacional da imagem maior, porém enriquece o nível de detalhes.

Outro ponto a se considerar além das resoluções de um sensor, é a necessidade de pré-processamento das imagens, como ajuste de inclinação e/ou equalização radiométrica. Alguns satélites implicam na prática dessas tarefas ao longo do estudo em questão, enquanto em outros, as imagens já são pré-processadas ([XIE; SHA; YU, 2008](#)).

A forma com que as ondas eletromagnéticas são capturadas pelos sensores remotos os diferem em sensores ópticos, sensores infravermelhos térmicos (ou passivos) e sensores de radar ativos ([JOSHI et al., 2007](#)). O tipo do sensor escolhido implica em vantagens e desvantagens em relação aos outros, por exemplo, os sensores ópticos possuem resolução maior quando comparado com o sensores de radar ativos, contudo, estes capturam informação de altura do solo ([FRANCESCHETTI; LANARI, 2018](#)). Consequentemente, alguns estudos utilizam abordagens híbridas desses sensores propiciando ganhos nas aplicações relacionadas ao solo terrestre, porém faltam ferramentas que auxiliem a integração dos dados desses coletores para essas abordagens ([JOSHI et al., 2007](#)).

A partir das informações referentes aos sensores remotos disponíveis, o conhecimento de quais características devem ser analisadas para a escolha do coletor e, consideradas as respectivas coberturas de cada sensor, é possível determinar os mais adequados e assim, obter suas respectivas imagens.

## 3.2 Segmentação

Após a seleção dos satélites e coleta das imagens, a próxima etapa é a segmentação para a subsequente análise ([BLASCHKE, 2010](#)). Essa fase pode ser definida como o processo na qual é realizada a divisão da imagem em várias regiões ou blocos de objetos, baseadas em um ou mais critérios de homogeneidade, sem que haja sobreposição destas ([SCHIEWE, 2002](#)).

Esse processo tem papel fundamental nos estudos de imagens de SR relativos à

cobertura e mudança de solo, entretanto, é um desafio ainda não solucionado (GAETANO et al., 2015; SUN; WANG, 2018).


### 3.2.1 *Marker-controlled watershed-based segmentation*

Objetos pequenos podem ser segmentados com mais detalhes em imagens adquiridas de sensores remotos, como Plêiades ou IKONOS, uma vez que as resoluções espaciais atingem valores abaixo de 1 metro em bandas pancromáticas. No entanto, as bandas multi-espectrais que compõem essas imagens possuem baixas resoluções. Para obter imagens com maiores detalhes, é necessário a aplicação da técnica de *pansharpening*, na qual é feita a fusão das informações geométricas da banda pancromática com a informação espectral das bandas de baixas resoluções espaciais (MENG et al., 2019). Contudo, o processo resulta em leves distorções e/ou desfoque espacial (GAETANO et al., 2015).

*Marker-Controlled Watershed-Based Segmentation* é um método proposto por Gaetano et al. (2015) com base no método *watershed* e em marcadores para segmentar regiões homogêneas e estabelecer resultados com maior valor semântico evitando a distorção causada pelo processo de *pansharpening*. Além disso, esse método pode ser facilmente executado e apresenta desempenhos promissores quando as regiões são reduzidas.

Na segmentação por *watershed*, o conceito é simular uma bacia hidrográfica. Primeiramente, são escolhidos diferentes pontos na superfície da figura e estes geralmente são encontrados por meio das cristas dos gradientes da imagem. Porém, devido à super-segmentação causada por essa técnica, Gaetano et al. (2015) executa um método de detecção de bordas e determina as origens das bacias através da distância entre os contornos encontrados. Posteriormente, esses pontos são continuamente preenchidos com “água” até serem completamente “inundados”, os quais são chamados de bacias hidrográficas (Figura 2). São criadas “barragens virtuais” no encontro entre as bacias o que darão origem às regiões da imagem e, conseqüentemente a segmentação.

Figura 2: Segmentação *watershed*.



Fonte: Elaborada pelo autor a partir de Derivaux et al. (2006).

Após a primeira etapa de segmentação, marcadores baseados nas propriedades

morfológicas e espectrais da imagem são criados automaticamente para auxiliar o método a evitar a super-segmentação, um efeito comum do método *watershed* e, garantir que objetos pequenos e grandes sejam extraídos com a mesma precisão.

Mesmo após a segmentação baseada em *watershed* e em marcadores segmentar as imagens de entrada, não há distinção entre as regiões resultantes. Esta tarefa é encarregada ao usuário, quaisquer que sejam seus objetivos.

### 3.2.2 Segmentação multi-escala

A segmentação multi-escala é uma abordagem hierárquica que ocorre de baixo para cima para segmentar uma imagem. O método inicia-se criando um resultado super-segmentado nos níveis de *pixels* ou *watershed* e por fim, essas várias regiões geradas são mescladas até que exista um resultado sub-segmentado com apenas um único segmento, representado pela imagem inteira (SANTOS et al., 2013). O método de segmentação multi-escala é comumente aplicado para imagens de SR em *softwares* comerciais, como eCognition e ENVI (GAETANO et al., 2015).

Um conhecido método de segmentação multi-escala foi proposto por Guigues, Cocquerez e Men (2006). Considere uma imagem  $I$  definida sobre um domínio  $D$  e segmentada por um método de segmentação  $P$ . Todas os segmentos criados por  $P$  são indexados por uma escala de um parâmetro  $\lambda$  e a saída de  $P_\lambda$  deve estar incluída em apenas uma região de  $P_{\lambda-1}$ , portanto,  $P_1$  é uma partição mais grossa que  $P_2$ , ou seja,  $\lambda_1 \leq \lambda_2$ . Como mencionado acima,  $P$  inicia a segmentação em um nível de *pixel* ou *watershed* e segue mesclando as regiões com as adjacentes até que resulte apenas um segmento. O processo de união entre as regiões é baseado na otimização de um critério, como por exemplo, a energia de Mumford-Shah (MUMFORD; SHAH, 1989), comumente utilizado que depende da cor dos *pixels* e dos comprimentos das arestas. A Equação 3.1 exemplifica o critério em que  $E_D$  é a distância com a imagem de entrada do modelo e  $E_C$  é o comprimento do contorno.

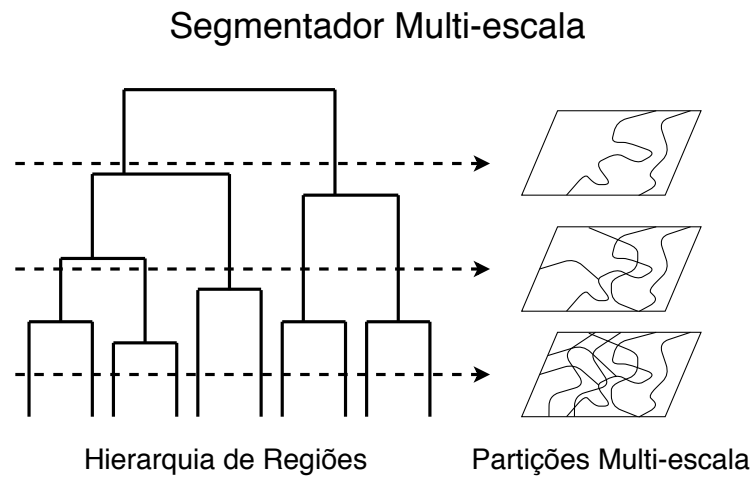
$$E(P) = \sum_{Ri \in P} E_D(Ri) + \lambda E_C(Ri) \quad (3.1)$$

A aproximação de cada região e o comprimento total de todas as arestas variam de acordo com  $\lambda$ . Para obter uma aproximação considerável de cada região, o  $\lambda$  deve ser pequeno, porém o comprimento total de todas as arestas será elevado. Entretanto, se  $\lambda$  for grande a aproximação será prejudicada, mas o comprimento total de todas as arestas será reduzido. A Figura 3 mostra essa segmentação hierárquica multi-escala.

O método de segmentação multi-escala oferece vários resultados em diferentes níveis de segmentação. Sendo assim, é responsabilidade do pesquisador selecionar a melhor escala resultante para a pesquisa realizada. Outra maneira de aproveitar esses resultados é



Figura 3: Segmentação multi-escala.



Fonte: Elaborada pelo autor a partir de [Santos et al. \(2013\)](#).

extraindo recursos de todas as escalas. Em ambos os casos, esse método precisa de uma técnica complementar para obter valores mais refinados.

### 3.2.3 Segmentação híbrida

A segmentação é um dos maiores desafios no processamento de imagens e o interesse pelos métodos híbridos tem aumentado recentemente devido a sua boa performance ao explorar sinais espectrais e os contornos em toda a figura. A estratégia de realizar uma super-segmentação e, em sequência, mesclar as regiões com mesmo valor semântico é considerado tendência para alcançar melhores resultados ([YANG; HE; CASPERSEN, 2017](#)).

A literatura contém critérios como base para mesclar essas regiões: variação, variação ponderada da área, Moran I, ângulo espectral, medida F, propriedades espectrais e geométricas. Para detectar as relações adjacentes, os métodos mais comuns são o RAG e o grafo dos vizinhos mais próximos ([HOSSAIN; CHEN, 2019](#)).

Outro método de segmentação híbrido foi desenvolvido por [Troya-Galvis, Gançarski e Berti-Équille \(2018b\)](#). Ao invés da técnica padrão de mesclagem de regiões, foram combinadas as saídas da técnica de classificação e método de segmentação alcançando melhores resultados de classificação e redução dos erros de segmentação.

Como uma terceira abordagem de métodos híbridos de segmentação, [Hislop et al. \(2019\)](#) abordaram técnicas de *ensemble* para detecção de distúrbios nas florestas da Austrália com o auxílio de imagens de SR capturadas pelos satélites do tipo Landsat. O estudo fez uso de dois algoritmos de detecção de mudanças, *LandTrend* ([KENNEDY;](#)

YANG; COHEN, 2010) e *R package strucchange* (ZEILEIS, 2006), que foram baseados em três índices de vegetação: NDVI, *Normalized Burn Ratio* (NBR) e *Tasseled Cap Wetness* (TCW). Cada combinação foi responsável pela origem de um mapa de distúrbios, o que levou a seis diferentes resultados que foram então combinados em dois métodos de comitê para gerar o mapa de distúrbio final do método proposto. O primeiro *ensemble*, fez uso de regras simples nas quais eram necessários ao menos dois dos seis resultados de detecções de mudanças para considerar cada *pixel* como uma região de distúrbio no resultado final. Aplicando a mesma lógica, também foram analisados os resultados considerando três e quatro dos seis resultados, respectivamente, para propagar o distúrbio para o resultado final. O segundo método foi realizado através da técnica de classificação RF. Os resultados dos experimentos demonstraram que a utilização de métodos de comitê favorece a redução do erro na busca por distúrbios em florestas.

### 3.3 Índices de vegetação

Ao menos cem índices de vegetação diferentes são adotados em um número razoável de estudos com objetivos distintos relacionados às imagens de sensoriamento remoto. Um exemplo é a detecção de mudanças na cobertura do solo (XUE; SU, 2017). Mesmo assim, o NDVI é predominante na avaliação de desmatamento devido à forte correlação entre a área foliar verde, biomassa, porcentagem de cobertura vegetal, produtividade e atividade fotossintética encontrada por este (SCHULTZ et al., 2016; HUETE, 1988).

O valor do índice (Equação 3.2), resultado da razão entre duas bandas espectrais, vermelho (*RED*) e infravermelho próximo (*NIR*) varia de 1, simbolizando plantas saudáveis, a -1, representando água. Também, os valores próximos a 0 referem-se à ausência ou reduzida quantidade de vegetação (SCHULTZ et al., 2016). Ademais, esses valores não são influenciados pelo efeito da sazonalidade, ou seja, os valores não se alteram ao longo do ano sem que haja a influência de um fator humano (SILVEIRA et al., 2018).

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (3.2)$$

Embora amplamente explorado, o NDVI nem sempre tem boa precisão. Uma das razões possíveis para explicar resultados inferiores é o fato desse índice ser sensível aos efeitos do brilho e da cor do solo (XUE; SU, 2017; FERREIRA et al., 2007). Para suprimir essa deficiência, foi adicionado um novo parâmetro *L* à Equação 3.2 que pode variar entre 0 e 1 e é inversamente proporcional à quantidade de vegetação na imagem. A essa variação do NDVI, deu-se o nome de índice de vegetação de ajuste do solo (do inglês *Soil-Adjusted Vegetation Index* - SAVI) (Equação 3.3) (XUE; SU, 2017). Quando *L* = 0, SAVI e NDVI têm o mesmo valor; caso contrário, valores mais próximos de 1 significam que o solo não influencia o resultado, o que é incomum em ambientes naturais (XUE; SU, 2017). A

Figura 5 e a Figura 6 demonstram, respectivamente, a diferença entre os resultados do NDVI e SAVI aplicado a uma imagem capturada com o satélite CBERS 4 em 2020 da cidade de Mogi das Cruzes (Figura 4). Neste caso, quanto mais vermelho o *pixel*, menos plantas existem e, portanto, quanto mais verdes mais saudável está a vegetação.


$$SAVI = \left( \frac{NIR - RED}{NIR + RED + L} \right) * (1 + L) \quad (3.3)$$

Figura 4: Imagem original.




Fonte: Elaborada pelo autor.

Figura 5: NDVI.



Fonte: Elaborada pelo autor.

Figura 6: SAVI.



Fonte: Elaborada pelo autor.

É comum localizar trabalhos que objetivam encontrar regiões onde há a probabilidade de desmatamento, nos quais o parâmetro  $L$  do SAVI é adotado como 0,5. Embora os resultados dessas pesquisas sejam promissoras e o SAVI tenha sido o único método de segmentação aplicado a elas, o que descarta a possibilidade de um resultado superior

explicado por uma abordagem híbrida, é necessário designar valores limites para detectar as alterações florestais. [Silveira et al. \(2017\)](#) concluíram que quanto maior a resolução espacial da imagem, menor é a diferença entre os índices de vegetação de florestas e áreas desmatadas. Conseqüentemente, resultados ruins podem ser alcançados devido ao uso de um valor limiar incerto ([KATSUHAMA et al., 2018](#); [CASALEGNO et al., 2017](#)).

## 3.4 Aprendizado de máquina

O objetivo das técnicas de AM é adquirir conhecimentos por meio de conjunto de dados de forma automática e realizar tarefas de reconhecimento, classificação, entre outras através desse conhecimento ([ROSSI, 2009](#)). No ramo do SR, vários estudos empregam técnicas de AM em prol de diversos objetivos. Em particular, no que se refere ao desflorestamento, técnicas de AM são amplamente aplicadas para monitorar florestas e encontrar taxas anuais de desmatamento ([LUZ et al., 2014](#); [HANSEN et al., 2016](#)). Com a finalidade de extrair conhecimento referente a florestas e solos expostos em uma imagem de SR, por exemplo, uma considerável quantidade de dados precisa ser apresentada para os algoritmos. Além disso, a representação da imagem por meio de *pixels* pode não ser uma boa estratégia ([BLASCHKE, 2010](#)). Alternativamente, extrai-se as características mais importantes dessa imagem para apresentá-la à técnica de AM ([PENATTI; VALLE; TORRES, 2012](#)). Portanto, ao invés de representar a imagem por um conjunto de *pixels*, deve-se representá-la como um vetor de características. Ademais, quais características serão utilizadas pode determinar o sucesso ou fracasso da técnica de AM.


### 3.4.1 Métodos de extração de características

Ao invés de extrair o conhecimento da imagem de um modo *pixel a pixel*, uma técnica comumente utilizada na literatura é a divisão da imagem em fragmentos de tamanhos fixos. Por meio desse processo, regiões de diferentes dimensões são representadas por partes de mesmo tamanho. A [Figura 7](#) representa uma imagem extraída do satélite CBERS 4 dividida em fragmentos de 15x15 *pixels*.

Cada parte da [Figura 7](#) é traduzida para um vetor de características por ação dos métodos de extração de características. Eles se baseiam em texturas, formas, cores e são as entradas das técnicas de AM.

Em [Santos et al. \(2013\)](#), diferentes métodos de extração de características foram analisados para identificação de pastos e campos de café e, de acordo com este estudo, os melhores métodos para trabalhar com a vegetação são: *Joint Auto-Correlogram*, *Color-Based Clustering*, *Color-bitmap*, *Quantized Compound Change Histogram* (QCCH) e *Invariant Steerable Pyramid Decomposition*.

Figura 7: Fragmentação da imagem de SR com tamanho de 15x15 *pixels*.



Fonte: Elaborada pelo autor.

O desempenho preditivo de um classificador depende da representatividade das características geradas pelo descritor escolhido (CHENG; HAN, 2016; MAXWELL; WARNER; FANG, 2018). Penatti, Valle e Torres (2012) e Santos et al. (2013) estudaram e identificaram eficácia na união de diferentes métodos descritores como forma de superar deficiências individuais. Outra análise interessante foi a relação entre os diferentes algoritmos. Sendo assim, a união de técnicas complementares aumenta a probabilidade de obtenção de resultados significativos na etapa posterior.

### 3.4.2 *Augmentation*

Como a técnica de classificação não é aplicada ao nível de *pixel*, existe a possibilidade de um fragmento conter mais dados de uma classe estudada e reduzindo-se o tamanho da divisão da imagem, essa probabilidade também é reduzida. Entretanto, os métodos de extração de características limitam esse tamanho, pois não as identificam em imagens pequenas. Além disso, quanto menor o tamanho do fragmento utilizado, mais suaves serão as bordas geradas pelo segmentador criado com a técnica de classificação.

A técnica de *augmentation* permite que fragmentos reduzidos, cujo tamanho impossibilita a extração de características, aumentem a dimensão desses elementos virtualmente de modo a eliminar a necessidade de mudança do tamanho real.

Existem vários métodos de *augmentation*, como por exemplo, a rotação da imagem, aplicação de *zoom* e mudança do contraste (MIKOŁAJCZYK; GROCHOWSKI, 2018). Mikołajczyk e Grochowski (2018) compararam diferentes métodos para análise de imagens de diagnósticos médicos e concluíram que a probabilidade de adicionarem novas informações para as técnicas de AM é limitada, porém se mostram úteis para incrementar o tamanho das bases de dados. Sendo assim, o uso das técnicas de *augmentation* permitem que fragmentos

com tamanhos de  $5 \times 5$  *pixels* obtenham resultados iguais ou superiores a fragmentos maiores durante o processo de classificação.

### 3.4.3 Técnicas de classificação

Após descrever cada fragmento da imagem em uma lista de vetores de características, no aprendizado supervisionado, é requerido o auxílio de um especialista que deverá classificar previamente esses vetores entre diferentes classes, conforme a necessidade do problema investigado. Assim, os algoritmos podem ser treinados e avaliados com os conhecimentos transmitidos por esses especialistas.

Durante o processo de aprendizado supervisionado, as amostras (vetores de características que representam os fragmentos) devem possuir rótulos referente a classes as quais elas pertencem. Por se tratar de um problema de classificação, essas classes precisam ser discretas (ROSSI, 2009).

Durante o processo de treinamento, o objetivo é que a técnica de AM construa um modelo (classificador) que seja capaz de identificar as classes das amostras a partir dos vetores de entrada (vetores de características). É importante salientar que para avaliar esse modelo, identificando sua taxa de acerto e capacidade de generalização, é necessário utilizar amostras que não foram empregadas no processo de treinamento (ROSSI, 2009).

De acordo com Cheng e Han (2016), SVM, *Adaboost*, kNN, *Conditional Random Field* (CRF), *Sparse Representation-based Classification* (SRC) e Rede Neural Artificial (RNA) são as técnicas mais comuns de AM aplicadas para classificar imagens de SR. Além disso, aprendizado ativo e *ensemble* são técnicas que alcançam bons resultados usando um número menor de amostras, acelerando o processo de treinamento do modelo (DALLAQUA; FARIA; FAZENDA, 2018).

Nesse contexto, as técnicas baseadas em aprendizagem profunda são consideradas estado da arte para analisar mudanças de solo e desmatamento. Essas técnicas geram modelos complexos que, geralmente, são mais precisos que outros modelos de aprendizado (ZHANG; ZHANG; DU, 2016). Tais técnicas de aprendizado profundo foram introduzidas em muitos estudos recentes de classificação de vegetação (KUSSUL et al., 2017). Entretanto uma grande quantidade de imagens é necessária para a indução do modelo, haja vista a grande complexidade destes que possuem milhares de parâmetros a serem ajustados.

Além disso, os resultados gerados por classificadores podem ser prejudicados pelo fato das imagens de sensoriamento remoto serem imagens de cenário aberto e, portanto, é razoavelmente fácil encontrar fragmentos com características diferentes das classificadas anteriormente por especialistas, prejudicando, assim, os resultados (JÚNIOR, 2018).

## 3.5 Métodos de avaliação

Os métodos de avaliação auxiliam na comparação de diferentes métodos de segmentação e técnicas de classificação. Através dessas medidas é possível retirar conclusões e interpretar comportamentos de maneira quantitativa.

### 3.5.1 Classificação

A avaliação das técnicas de classificação com foco em problemas binários ou multi-classes pode ser realizada de forma a validar a habilidade de generalização durante a fase de treinamento do modelo. Uma medida usualmente empregada para essa tarefa é a acurácia (Equação 3.4) (HOSSIN; SULAIMAN, 2015). Além dessa, outras medidas também fazem uso de uma matriz de confusão (Tabela 1), cujo conteúdo contém informações de classes positivas e negativas corretamente classificadas.

Tabela 1: Matriz de confusão para classificação binária.

	Classe Positiva Atual	Classe Negativa Atual
Predição da Classe Positiva	Verdadeiro Positivo (tp)	Falso Negativo (fn)
Predição da Classe Negativa	Falso Positivo (fp)	Verdadeiro Negativo (tn)

Fonte: Elaborada pelo autor a partir de Hossin e Sulaiman (2015).

$$acc = \frac{tp + tn}{tp + fp + tn + fn} \quad (3.4)$$

A medida de acurácia estabelece a relação entre as amostras preditas corretamente e o número total de amostras. Entretanto essa medida pode não ser adequada quando há um desbalanceamento entre classes. Em contrapartida o método de avaliação F-Medida (Equação 3.5) indica uma relação harmônica baseado nas métricas de precisão (exemplos positivos corretamente preditos sobre o total de amostras da classe positiva, Equação 3.6) e revocação (padrões positivos corretamente classificados, Equação 3.7).

$$FM = \frac{2 * p * r}{p + r} \quad (3.5)$$

$$p = \frac{tp}{tp + fp} \quad (3.6)$$

$$r = \frac{tp}{tp + tn} \quad (3.7)$$

Outra medida importante é a *Area under the ROC Curve* (AUC), pois esta é mais aconselhável para eleger as melhores soluções que as medidas de acurácia. AUC reflete uma classificação de performances das técnicas avaliadas e é calculada segundo a Equação 3.8,

onde  $S_p$  é a soma dos valores positivos e  $n_p$  e  $n_n$  são os números de amostras positivas e negativas respectivamente (HOSSIN; SULAIMAN, 2015).

$$AUC = \frac{S_p - n_p(n_n + 1)/2}{n_p n_n} \quad (3.8)$$

Para calcular essas medidas, a validação dos métodos de classificação comumente utilizada na literatura é realizada pelo método de re-amostragem de validação cruzada estratificada. Isso implica que o conjunto de dados deve ser dividido em  $k$  partições contendo aproximadamente a mesma quantidade de exemplos de cada classe. Dessas,  $k - 1$  devem ser usadas para o treinamento do método, enquanto a partição restante é utilizada para teste. O processo é realizado  $k$  vezes, cada momento com uma parte diferente para teste. O resultado final é a média das  $k$  subdivisões de teste. Um dos valores amplamente utilizados para  $k$  na literatura é igual a 10 (ROSSI, 2009).

### 3.5.2 Segmentação

Para avaliar os resultados dos métodos de segmentação, as medidas *Global Consistency Error* (GCE) e *Local Consistency Error* (LCE) podem ser empregadas devido as suas capacidades de qualificar quantitativamente os segmentos gerados. As medidas são baseadas numa equação de erro (Equação 3.9) que requer a presença de um *ground truth* para comparação, portanto, é necessário que um especialista crie uma segmentação manualmente das imagens analisadas. GCE e LCE são projetados para serem tolerantes a sub-regiões, ou seja, o erro é baixo se a região avaliada estiver dentro da região segmentada como *ground truth* (DORINGA et al., 2010; KUMAR; MANJUNATH, 2017).

A Equação 3.9 que indica o erro da segmentação é calculado considerando cada *pixel*  $p_i$ , em que  $R(S_j, p_i)$  é a região da segmentação  $j$  que contém  $p_i$ .  $\setminus$  é a diferença do conjunto e  $|\cdot|$  é a cardinalidade do conjunto.

$$E(S_1, S_2, p_i) = \frac{|R(S_1, p_i) \setminus R(S_2, p_i)|}{|R(S_1, p_i)|} \quad (3.9)$$

A partir do erro em cada *pixel*, ambas as medidas, GCE e LCE, podem ser calculadas:

$$GCE(S_1, S_2) = \frac{1}{n} \min\left(\sum_i E(S_1, S_2, p_i), \sum_i E(S_2, S_1, p_i)\right) \quad (3.10)$$

$$LCE(S_1, S_2) = \frac{1}{n} \sum_i \min(E(S_1, S_2, p_i), E(S_2, S_1, p_i)) \quad (3.11)$$

O GCE força todas as sub-regiões locais a estarem na mesma direção e o LCE permite que elas ocorram em diferentes direções da segmentação (DORINGA et al., 2010).



Outro modo de avaliar a segmentação é através das medidas derivadas da matriz de confusão. Similar a matriz evidenciada na [Subseção 3.5.1](#), é levado em consideração os *pixels* classificados corretamente e erroneamente.

A partir da matriz, algumas medidas como Kappa Index, Tau Index e *Overall Accuracy* podem ser extraídas (FIELDING; BELL, 1997). Essas medidas aparecem frequentemente na literatura (SANTOS et al., 2013), entretanto, se tornam menos atraentes para avaliar métodos de segmentação que não possuem classificação.

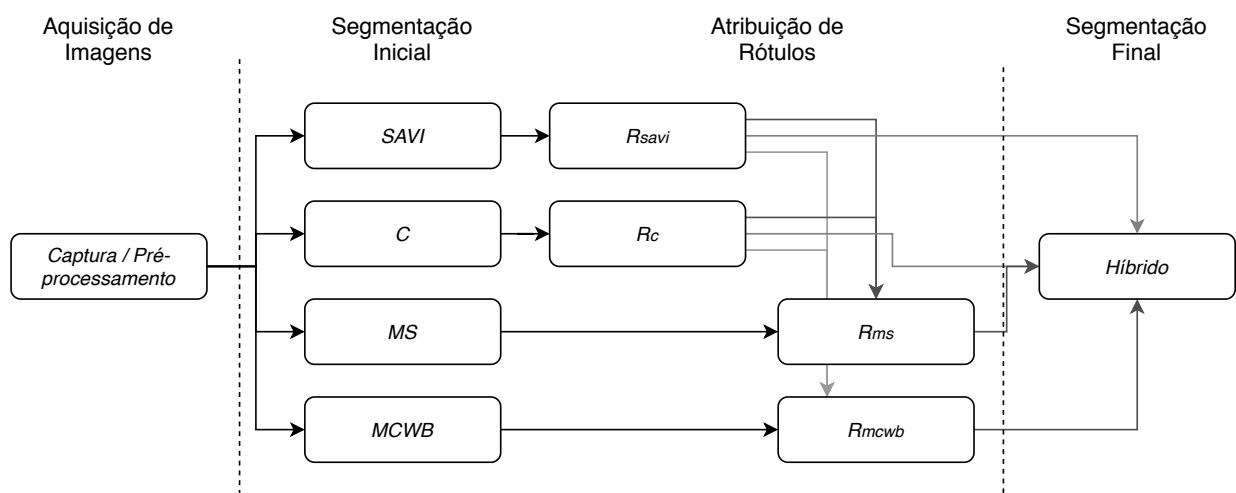


## 4 ABORDAGEM PROPOSTA

A abordagem desenvolvida neste trabalho compreende um sistema automático para detecção e sugestão de regiões de vegetações degradadas e regeneradas por meio de imagens de SR que pode ser dividido em três fases principais: captura das imagens, segmentação e votação. A primeira fase está relacionada com a aquisição e processamento das imagens de SR. Na segunda etapa, quatro métodos são empregados para segmentar as imagens considerando diferentes aspectos e mecanismos, como cobertura vegetal, detecção de bordas e reconhecimento de padrões. Como todos os métodos possuem deficiências, a combinação dos resultados gerados por cada um pode superar esses limites e melhorar a segmentação final. Assim, na última fase, é realizada a combinação dos resultados de todos os métodos de segmentação, produzindo uma imagem em que cada segmento representa uma região com cobertura florestal ou de solo exposto. Essas regiões podem ser analisadas ao longo do tempo para apoiar o monitoramento de áreas de desmatamento.

A [Figura 8](#) representa o fluxo do método desenvolvido. Assim, a primeira etapa contém os quatro métodos de segmentação aplicados. Posteriormente, a segunda etapa demonstra que as regiões geradas pelo método *SAVI* e *C* possuem rótulos e influenciarão nas regiões criadas pelo *MS* e *MCWB*. Por último, a segmentação criada pelo método proposto é gerada com as informações dos outros métodos de segmentação.

Figura 8: Fluxo do método desenvolvido.



Fonte: elaborada pelo autor.

O estudo foi desenvolvido em sua maioria na linguagem de programação Python 3.6 com o auxílio dos módulos de desenvolvimento *Scikit-Learn* 0.21.1 e *Gdal* 3.0.4 sobre

o sistema operacional Ubuntu 18.04. Em menor quantidade foram utilizados códigos na linguagem Matlab 2017b.

## 4.1 Aquisição e pré-processamento de imagens

A primeira etapa do método criado objetiva capturar automaticamente as imagens e aplicar os processamentos necessários para que possam ser analisadas em sequência (segunda etapa).


Inicialmente, são elencadas e armazenadas todas as informações das imagens disponíveis para os sensores remotos, datas e regiões escolhidas. Para isso, um robô web (*web crawler*) foi desenvolvido para acessar o repositório de imagens empregado na pesquisa e extrair informações como datas e porcentagens de cobertura de nuvens dos dados disponíveis. O [Algoritmo 4.1](#) representa essa informação registrada no formato *JavaScript Object Notation* (JSON) de uma imagem com resolução espacial de 5m capturada com o sensor CBERS 4 em 06 de março de 2020 na órbita 152 e ponto 127 representado pela [Figura 9](#). As informações representadas por  $x_1$ ,  $x_2$ ,  $y_1$  e  $y_2$  caracterizam as coordenadas da imagem na projeção 32723.

Algoritmo 4.1: Meta-dados de uma imagem de SR coletada do repositório de imagens do INPE.

```
1 {
2   "id": 1,
3   "folder": "origin/CBERS-4-PAN-20200306-152-127.tif",
4   "name": "CBERS4-PAN5M_152/127_2020-03-06",
5   "x_res": 5.0,
6   "y_res": -5.0,
7   "x1": 487475.0,
8   "x2": 574520.0,
9   "y1": 7398685.0,
10  "y2": 7270940.0,
11  "firstQuarterCloud": 0.0,
12  "secondQuarterCloud": 0.0,
13  "thirdQuarterCloud": 0.0,
14  "fourthQuarterCloud": 0.0,
15  "srs": "32723",
16  "imageDescriptionList": [
17    {
18      "id": 1,
19      "key": "L",
20      "value": "2.0"
21    }
22  ]
23 }
```

```
22 ],
23 "number": "1/1",
24 "page": 1,
25 "imageSearchRegion": {
26     "id": 3,
27     "orbit": 152,
28     "point": 127
29 },
30 "downloaded": true,
31 "imageSearch": {
32     "id": 1,
33     "name": "CBERS4-5M",
34     "satelliteType": "CBERS4",
35 }
36 "imageSearchRegion": {
37     "id": 3,
38     "orbit": 152,
39     "point": 127
40 },
41 "dateTimestamp": 1583499120000,
42 "requestTimestamp": 1585215914461
43 }
```

Figura 9: Região representada pela órbita 152 e ponto 127.

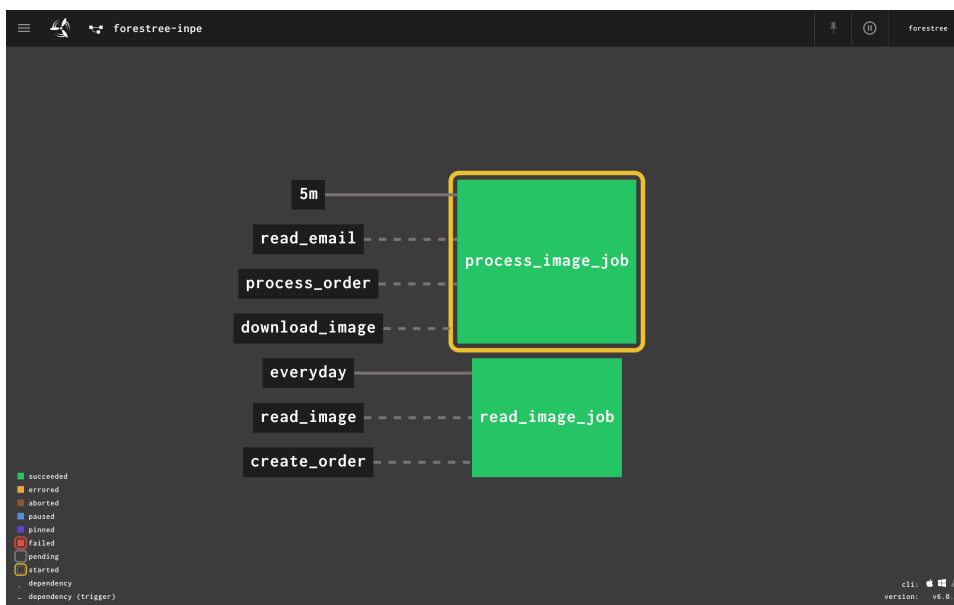


Fonte: retirada de <http://www.dgi.inpe.br>.

Os dados coletados permitem a aplicação de filtros pelo robô para eliminar as imagens cobertas por nuvens ou de regiões que não foram revisitadas posteriormente. Sendo assim, as imagens restantes são baixadas e processadas caso haja necessidade, como o processo de *pansharpening*, em que a banda pancromática com maior resolução é unida às bandas multi-espectrais e o processo de correção geográfica explicado no [Apêndice A](#).

Finalmente, para que o processo descrito nessa seção seja executado de forma automática, sem intervenção humana, uma ferramenta de automatização de *pipelines* executa a rotina a cada período de tempo pré-definido. Na [Figura 10](#) é apresentado um exemplo. Primeiramente, o processo de coleta de dados (“*read\_image\_job*”) é executado diariamente para capturar todas as informações das novas imagens adicionadas ao repositório e em sequência, criar um pedido para baixá-las. Posteriormente, o procedimento “*process\_image\_job*” é executado a cada 5 minutos para validar se o *e-mail* com o número e o link para *download* do pedido criado foi enviado. Consequentemente as imagens são baixadas e processadas. As cores verdes no fundo de cada bloco indicam que a última execução ocorreu sem que houvesse nenhuma falha e a cor amarela contornando o bloco “*process\_image\_job*” aponta que esse processo está sendo executado no momento.

Figura 10: Ferramenta de automatização executando a rotina.



Fonte: elaborada pelo autor.

Durante a etapa de pré-processamento e devido a uma limitação imposta pelo algoritmo de segmentação multi-escala, as imagens também foram particionadas em sub-imagens contendo um tamanho fixo de  $2\text{km}^2$ . Assim, todos os métodos de segmentação estão aptos a aplicarem a mesma imagem de entrada.

## 4.2 Segmentação

Na segunda fase, quatro métodos diferentes são empregados para a segmentação das imagens coletadas: i) classificação de regiões usando técnicas de AM (Seção 3.4); ii) definição de um limiar para classificação usando o SAVI (Seção 3.3); iii) método de segmentação multi-escala (Subseção 3.2.2); e iv) *marker-controlled watershed-based segmentation* (Subseção 3.2.1).

A técnica de AM é aplicada para classificar regiões da imagem de SR entre duas classes: floresta e não floresta. Para tal, ao invés de efetuar a tarefa por meio da informação presente em cada *pixel*, a imagem é dividida em sub-conjuntos ou fragmentos. A decisão sobre o tamanho desses fragmentos deve considerar principalmente a relação entre o desempenho preditivo do modelo de aprendizado e os limites produzidos por esses fragmentos. Em outras palavras, quanto menor o tamanho, mais suave os limites entre as regiões. Por outro lado, uma quantidade pequena de *pixels* em cada fragmento pode não ser suficiente para caracterizar uma região adequadamente.

Em sequência, são empregados um ou mais métodos de extração de características com o objetivo de identificar as feições de cada fragmento, obtendo assim, um vetor de características. Esse vetor é usado como sinal de entrada de um modelo de AM treinado previamente. Sendo assim, um fragmento que não foi utilizado durante o processo de treinamento do classificador poderá ser rotulado em floresta ou não floresta.

Muitas técnicas de AM podem ser usadas para executar esta tarefa. Como essa classificação é crucial para o sucesso da abordagem colaborativa, diferentes técnicas podem ser avaliadas e a que obtiver o melhor desempenho preditivo deve ser escolhida.

Outro modo para classificar essas regiões é por meio de um índice de vegetação. Devido as evidências, descritas no Capítulo 3, de obter melhor performance comparado aos outros índices, o SAVI é o segundo método de segmentação analisado. No entanto, este índice é capaz de classificar cada *pixel* apenas em vegetação ou em solo exposto, ao invés de floresta e não floresta.

A aplicação da equação correspondente ao SAVI gera um resultado que contém valores em um intervalo caracterizando o quão saudável a vegetação analisada está, entretanto esse índice exige que sejam empregados dois parâmetros para sua execução. O primeiro,  $L$ , é utilizado durante o cálculo do índice e indica a porcentagem de solo presente na imagem. O segundo, é um valor limite aplicado após a execução do SAVI para segmentar as regiões em vegetação ou em solo exposto. Para isso, valores constantes são sugeridos na literatura, porém outras técnicas podem ser aplicadas para selecionar esses parâmetros.

Uma das técnicas que pode ser aplicada para obtenção do parâmetro  $L$ , é através dos resultado dos algoritmos de AM, de modo em que a porcentagem encontrada de solo


exposto definirá o valor de  $L$ . Em outras palavras,  $L$  será o número de *pixels* classificados como não vegetação ou solo exposto ( $P(s)$ ) dividido pelo total de *pixels* ( $P$ ) na imagem (Equação 4.1). Ao invés de valores fixos, o uso de técnicas como a descrita, obtém parâmetros com mais precisão e possivelmente alcançará melhores resultados.

$$L = \frac{P(s)}{P} \quad (4.1)$$

O terceiro método aplicado é a segmentação multi-escala baseada em [Guigues, Cocquerez e Men \(2006\)](#) devido aos seus resultados consideráveis em várias pesquisas relacionadas a SR ([ZHANG; XIAO; FENG, 2020](#)). Esse método cria vários níveis de segmentação para as imagens, os quais são chamados de escalas. A [Figura 11](#) representa a escala mais fina do resultado obtido com o método, na qual os objetos são super-segmentados (*over-segmented*) e a [Figura 12](#) é uma escala superior, cujo segmentos apresentados na [Figura 11](#) estão agrupados.

Ao invés de procurar a segmentação mais acurada com a escala que melhor representa o problema em questão, foi adotada a escala mais fina gerada para o emprego do método na abordagem colaborativa, ocasionando um resultado super-segmentado (*over-segmented*). Essa decisão é embasada na probabilidade de delinear qualquer região possível por meio da escala mais fina, o que outros métodos talvez não consigam. Assim, os outros métodos baseados em região serão empregados para mesclar os segmentos fornecidos por esse algoritmo.

Figura 11: Escala mais fina gerada pelo método multi-escala.      Figura 12: Escala mais grossa gerada pelo método multi-escala.



Fonte: elaborada pelo autor.



Fonte: elaborada pelo autor.

Embora a segmentação multi-escala pode super-segmentar uma imagem quando a escala mais fina é utilizada, outros métodos podem fornecer regiões divergentes, pois são baseados em conceitos diferentes. Para esse propósito, foi incluída a segmentação



*marker-controlled watershed-based segmentation* (GAETANO et al., 2015) fundamentada na possibilidade de extrair objetos grandes e pequenos com elevada precisão. Esse método é uma abordagem híbrida que segmenta as imagens criando regiões com base em suas propriedades morfológicas e espectrais, como o formato dos objetos e as informações de cores presentes na imagem respectivamente.

### 4.3 Abordagem colaborativa

Na última fase da abordagem colaborativa, propõe-se um método para realizar a fusão das regiões segmentadas pelos diferentes métodos de segmentação, produzindo assim, apenas uma segmentação da imagem, em que cada segmento estará classificado como floresta ou não floresta. Seja  $I$  uma imagem de SR, os quatro componentes do método proposto (segmentação multi-escala, *marker-controlled watershed-based segmentation*, SAVI e classificação) são aplicados à imagem  $I$ , resultando em quatro imagens segmentadas, aqui denominadas de  $MS$ ,  $MCWB$ ,  $SAVI$  e  $C$  respectivamente. Cada região segmentada dessas imagens,  $R_{ms}$ ,  $R_{mcwb}$ ,  $R_{savi}$  e  $R_c$ , é composta por um conjunto de  $n$  *pixels*, sendo  $P_{i,j}$  cada *pixel* dessas regiões.

Todas as regiões que possuem um rótulo para identificá-las como uma área de vegetação ou não, que são os casos das regiões  $R_c$  e  $R_{savi}$ , denominadas genericamente de  $R_l$ . As regiões que não possuem essa classificação, como as regiões  $R_{ms}$  e  $R_{mcwb}$ , são denominadas  $R_{nl}$ .

Para que a abordagem colaborativa possa ser colocada em prática por meio da técnica de votação, primeiramente é necessário que as regiões  $R_{nl}$  sejam convertidas em  $R_l$ . Para isso, as regiões  $R_c$  e  $R_{savi}$  são consultadas com a finalidade de determinar se uma região  $R_{nl}$  representa uma área de vegetação ou solo exposto. Em outras palavras, deve ser encontrada  $R_c$  e  $R_{savi}$  mais correlacionadas com  $R_{nl}$ , comparando as regiões  $R_c$  e  $R_{savi}$  que possuem maior intersecção com  $R_{nl}$ , ou seja, mais  $P_{i,j}$  em comum. Assim, cada região  $R_c$  e  $R_{savi}$  é rotulada como vegetação (1) ou solo exposto (0). Portanto, a região  $R_{nl}$  recebe um rótulo 1 se  $R_c$  e  $R_{savi}$  forem vegetação ou 0, caso contrário.

Se  $R_c$  e  $R_{savi}$  tiverem classes diferentes, a taxa de correlação ( $CR$ ) será calculada e  $R_{nl}$  será preenchido com o rótulo da região mais correlacionada.  $CR$  é encontrada através de uma fração entre o número de *pixels* na intersecção de  $R_{nl}$  e  $R_c$  ou  $R_{savi}$  e o número de *pixels* em  $R_{nl}$  (Equação 4.2).

$$CR = \frac{|R_{nl} \cap R_c|}{|R_{ms}|} \quad (4.2)$$

Após todas as regiões correlacionadas encontradas e todas as regiões classificadas entre vegetação ou solo exposto, a técnica de comitê por meio de votação criará a segmen-

tação da abordagem colaborativa. Durante o processo de eleição, cada *pixel* da imagem  $P_{i,j}$  recebe votos de cada método de segmentação, ou seja, se  $P_{i,j}$  no resultado *SAVI* for classificado como vegetação, um voto para vegetação será computado, caso contrário, um voto para solo exposto é adicionado. Finalmente,  $P_{i,j}$  recebe a classe com mais votos. Após esse processo ser avaliado para todos os *pixels*, a saída final é criada.

O sistema de votação aplicado na presente pesquisa é similar ao método proposto por Hislop et al. (2019), os quais aplicaram a técnica de comitê em segmentações que utilizaram exclusivamente índices de vegetação como base para monitorar distúrbios. Por outro lado, a abordagem colaborativa proposta nesse estudo faz uso de outros três métodos de segmentação divergentes (segmentação multi-escala, *marker-controlled watershed-based segmentation* e classificação) e de forma independente. Outra diferença apresentada é relacionada ao método de busca por desmatamento, Hislop et al. (2019) aplica o método desenvolvido por meio de uma comparação de imagens, identificando os distúrbios entre elas e excluindo a etapa de classificação das regiões, enquanto o presente estudo classifica diferentes imagens entre solo exposto e vegetação para então compará-las e encontrar regiões desmatadas.

Esse algoritmo de duas etapas é representado da seguinte forma: o Algoritmo 4.2 apresenta a primeira fase em que é configurado o rótulo de cada  $R_{nl}$  e o Algoritmo 4.3 exemplifica como o resultado da abordagem colaborativa é construída.

Algoritmo 4.2: Método para atribuir *labels* às regiões não classificadas.

```

1 def set_label_to_regions(I: OriginalImage):
2     for R_nl in I:
3         R_c = find_equivalent_region(R_nl)
4         R_savi = find_equivalent_region(R_nl)
5
6         if R_c == 1 and R_savi == 1:
7             R_nl = 1
8         elif R_c == 0 and R_savi == 0:
9             R_nl = 0
10        else:
11            R_nl = CR

```

Algoritmo 4.3: Método para atribuir *labels* às regiões não classificadas.

```

1 def create_output(I: OriginalImage):
2     for P_ij in I:
3         F = 0
4         NF = 0
5
6         if R_ms == 1:
7             F += 1
8         else:
9             NF += 1

```

```

10
11     if R_c == 1:
12         F += 1
13     else:
14         NF += 1
15
16     if R_savi == 1:
17         F += 1
18     else:
19         NF += 1
20
21     if R_mcwb == 1:
22         F += 1
23     else:
24         NF += 1
25
26     if F > NF:
27         P_ij = 1
28     else:
29         P_ij = 0

```


A Figura 13 até a Figura 17 é um exemplo do método descrito anteriormente. Considere a Figura 13 como a imagem original ( $I$ ), a Figura 14 como a resultado de *marker-controlled watershed-based segmentation* ( $MCWB$ ) e a Figura 16 como a resultado do método SAVI ( $SAVI$ ). Portanto, nesse cenário, as regiões de  $MCWB$  e  $SAVI$  são identificadas por  $R_{nl}$  e  $R_l$  respectivamente. Devido as regiões geradas por  $MCWB$  não possuírem classificações, devem ser encontradas as regiões de maior correlação para cada  $R_{mcwb}$ . Para demonstrar o processo, foi extraído uma região  $R_{mcwb}$ , representada pela Figura 14. Conseqüentemente, a região  $R_{savi}$  apresentada na Figura 17 é a região correspondente a  $R_{mcwb}$  porque a maioria dos *pixels* em  $R_{savi}$  está presente em  $R_{mcwb}$ .

Com base nesse exemplo, suponto que a região de maior correlação do método de classificação  $R_c$  possúisse um rótulo 1, poderia concluir-se que a região presente na Figura 15 ( $R_{mcwb}$ ) será rotulada com a classe 1, pois  $R_{savi}$  (Figura 17) também possui o rótulo 1.


## 4.4 Comparação de imagens

Após a segmentação híbrida das imagens de SR, inicia-se a busca por áreas degradadas e regeneradas. Nesse processo, imagens da mesma região capturadas em diferentes momentos no tempo são comparadas, ou seja, uma imagem antiga é confrontada com outra recente e as regiões que possuíam a classe de vegetação na imagem antiga e se tornaram solo exposto na figura recente são realçados identificando as áreas desmatadas.

Figura 13: Imagem original.



Fonte: Elaborada pelo autor.

Figura 14: Segmentação  $MCWB$ .Fonte: Elaborada pelo autor.  
Figura 16: Segmentação  $SAVI$ .

Fonte: Elaborada pelo autor.

Figura 15: Região  $R_{mcwb}$ .Fonte: Elaborada pelo autor.  
Figura 17: Região  $R_{savi}$ .

Fonte: Elaborada pelo autor.

A lógica inversa é aplicada para encontrar as regiões regeneradas (regiões que possuíam a classe de solo exposto na imagem antiga e se tornaram vegetação na figura recente).

A [Figura 18](#) e a [Figura 19](#) exemplificam o método de comparação por meio de duas segmentações, sendo uma de maio de 2018 e outra de julho de 2018. As regiões verdes indicam as áreas onde existem vegetação e marrom onde o solo está exposto. Conseqüentemente, as áreas em amarelo na [Figura 20](#) representam todas as áreas que em maio eram vegetação e em julho foram classificadas como solo exposto.

Figura 18: Resultado da abordagem colaborativa em maio de 2018.



Fonte: elaborada pelo autor.

Figura 19: Resultado da abordagem colaborativa em julho de 2018.



Fonte: elaborada pelo autor.

Figura 20: Resultado da comparação entre a [Figura 18](#) e a [Figura 19](#)



Fonte: elaborada pelo autor.



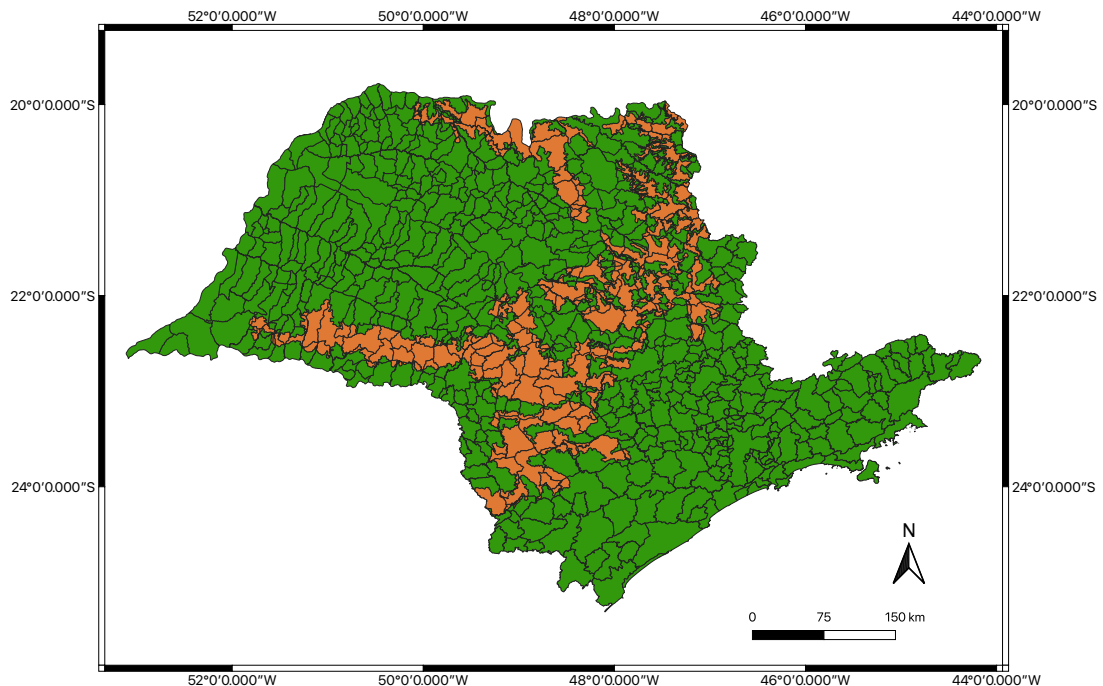
## 5 EXPERIMENTOS

Nesta seção é apresentada a metodologia experimental empregada para avaliar o método proposto no [Capítulo 4](#).

### 5.1 Área de estudo e dados de referência

O Estado de São Paulo está localizado no sudeste do Brasil e tem uma área de 1.521.110 km<sup>2</sup>, equivalente a aproximadamente 17,83% do território nacional. É coberto por duas diferentes vegetações: mata atlântica e cerrado ([Figura 21](#)). Em 2019, a projeção da população no estado foi de 45.919.049 (IBGE), cerca de 21,85% da população brasileira, o que contribui para aumentar os índices de desmatamento no país.

Figura 21: Cobertura vegetal do Estado de São Paulo: i) região verde distingue a Mata Atlântica brasileira e ii) região alaranjada identifica Cerrado brasileiro.



Fonte: Adaptado do Mapa de Vegetação do Brasil IBGE (2003).

Para conter esse efeito de desflorestamento e garantir a preservação desses biomas na região, a Polícia Militar Ambiental do Estado de São Paulo realiza a fiscalização e autua as infrações ambientais diariamente. Os dados coletados durante essa rotina de policiamento foram disponibilizados para a pesquisa com o objetivo de auxiliar no processo de validação dos resultados. Esse banco de dados contém 69.381 autuações de infrações ambientais entre

2015 e 2019, os quais foram reduzidos a 9.728 registros devido a restrição das autuações com a descrição relacionada a supressão de vegetação. Foi constatado que 3.159 autuações possuem uma área circular inferior a  $98\text{m}^2$  e 75% desses dados possuem área exata de  $97\text{m}^2$ , o que dificulta a análise visual através das imagens de SR. Portanto, foram mantidas somente as autuações com uma área superior a  $97\text{m}^2$ . É possível encontrar nos arquivos compartilhados informações como *shapefile* da área desmatada, ano da infração, município, coordenadas geográficas e *status* da infração.

O *shapefile* contém os polígonos que representam as regiões onde ocorreram as infrações ambientais. Eles foram produzidos manualmente com o auxílio de aparelhos de GPS, ou seja, um policial deslocou-se até a região de autuação e caminhou ao redor da área, demarcando as suas coordenadas conforme [Figura 22](#). Esse arquivo permite confrontar o estudo da abordagem colaborativa com casos reais de desmatamento e assim, eliminar a subjetividade gerada pelo uso de dados incorretos.

Figura 22: Autuação de desmatamento na cidade de Jacupiranga em 2017 e 2018 aplicada sobre imagem do *Google Earth*.



Fonte: Adaptado do *Google Earth*.


Em relação às imagens, dois conjuntos foram analisados para avaliar este estudo. Embora dependam de outras fontes de iluminação, como o Sol, e estão suscetíveis a obstrução por nuvens, essas imagens foram capturadas com o auxílio de sensores ópticos, devido a apresentarem maiores resoluções espaciais. Ambos os conjuntos foram baixados



de forma automática pelo repositório de imagens do INPE<sup>1</sup> com o uso da ferramenta Concourse CI<sup>2</sup>.

O primeiro conjunto de imagens foi adquirido pela constelação RapidEye, um conjunto de 5 satélites comerciais alemães idênticos que possuem uma resolução temporal diária. A constelação foi lançada em agosto 2008, possui uma resolução radiométrica de 12 bits e 5 bandas espectrais (azul, verde, vermelho, *red-edge* e infravermelho próximo). As imagens adquiridas foram referentes as órbitas/pontos ocupadas pelo Estado de São Paulo no período de 2011 a 2013. A **Figura 23** foi capturada pelo sensor Reis, que faz parte da constelação RapidEye, em 2011 na cidade de São José das Laranjeiras-SP.

Figura 23: Imagem capturada pela constelação RapidEye em 2011 na cidade de São José das Laranjeiras.



Fonte: Elaborada pelo autor.

O segundo conjunto de imagens foi coletado de um satélite brasileiro lançado em 2014 em parceria com a China, Missão *China-Brazil Earth Resources Satellite* (CBERS) ou Satélite Sino-Brasileiro de Recursos Terrestres. O coletor possui uma câmera pancromática com três bandas multi-espectrais e uma pancromática, ambos com resolução radiométrica de 8 bits e temporal de 52 dias. As bandas multi-espectrais são compostas pelas bandas

<sup>1</sup> <http://www.dgi.inpe.br/CDSR/>

<sup>2</sup> <https://concourse-ci.org>

verde, vermelho e infravermelho próximo e possui uma resolução espacial de 10m. Contudo, a banda pancromática contém uma resolução espacial de 5m o que permite o processo de *pansharpening*, no qual as 4 bandas são mescladas por meio de *software* e uma única imagem multi-espectral com resolução espacial de 5m é criada. A [Figura 24](#) representa a captura pelo satélite CBERS 4 em 2020 na região de Mogi das Cruzes e sofreu o processo de *pansharpening*, portanto, possui 5m de resolução espacial.

Figura 24: Imagem capturada pelo satélite CBERS 4 em 2020 na região de Mogi das Cruzes - SP.



Fonte: Elaborada pelo autor.

Ambos os satélites estão ativos, porém o repositório de imagens utilizado não possui imagens capturadas pelos sensores da constelação RapidEye posteriormente a 2014, por isso, as imagens do satélite CBERS 4 são importantes para avaliar os resultados adquiridos com os dados de autuações da Polícia Militar Ambiental do Estado de São Paulo. Além do mais, as imagens auxiliam a comprovar a eficácia do método proposto independente do conjunto de imagens testados. A [Tabela 2](#) contém os detalhes dos satélites analisados durante a pesquisa.

Por último, após a busca manual pelas imagens anteriores e posteriores às autuações, nas quais seria possível visualizar os desmatamentos, bem como as correções geométricas conforme descrito no [Apêndice A](#), uma representação de 19 autuações de desmatamento ilegal no estado de SP foram encontradas aleatoriamente nos conjunto de dados da polícia. Foram segmentadas e comparadas 80 sub-imagens de 2km<sup>2</sup> coletadas pelo satélite CBERS-4

Tabela 2: Informações referente aos sensores remotos estudados.

	<b>Landsat 8</b>	<b>RapidEye</b>	<b>CBERS 4</b>
<b>Resolução Espacial</b>	30m	5m	5m
<b>Resolução Temporal</b>	16 dias	diária	52 dias
<b>Resolução Radiométrica</b>	16 bits	12 bits	8 bits
<b>Lançamento</b>	2013	2008	2014
<b>Status</b>	Ativo	Ativo	Ativo
<b>Imagens disponíveis</b>	2015 - 2020	2011 - 2014	2015 - 2020

Fonte: Elaborada pelo autor.

com essas autuações. Além do mais, uma autuação pode estar contida em um espaço maior que o tamanho de uma sub-imagem e assim se faz necessária a análise das sub-imagens adjacentes.

## 5.2 Extração de características

Para classificar uma imagem de SR com o uso de técnicas de AM, é necessário fragmentá-las em várias partes, sendo assim, cada qual será rotulada e a união dos fragmentos resultarão na classificação da imagem. Quanto menor o tamanho do fragmento, mais suave será o realce das bordas realizado pela segmentação por meio dessa técnica, entretanto, quanto menor o fragmento, maior é a dificuldade de extrair suas características.

Nas experiências realizadas nesse estudo foram avaliados fragmentos de tamanhos de 30x30, 15x15, 10x10 e 5x5 *pixels*. Essas dimensões foram encontradas na literatura como tamanhos suficientes para caracterizar informações sobre vegetações, além de expressar uma boa representação do solo, pois devido ao conjunto de imagens possuírem 5m de resolução espacial, os fragmentos representam de 150m<sup>2</sup> a 25m<sup>2</sup> (SANTOS et al., 2013; TRANCOSO; SANO; MENESES, 2015).

Após a fragmentação, os métodos de extração de características são utilizados para extrair as informações de cada porção, para isso foram analisados métodos baseados em textura e cores. Essas técnicas foram apresentados em Santos et al. (2013), Penatti, Valle e Torres (2012) e Oliva e Torralba (2006): Descritor de Co-ocorrência de Cores, Histogramas de Gradientes Orientados (*Histogram of Oriented Gradients* - HOG), Descritor Homogêneo de Textura (*Homogeneous Texture Descriptor* - HTD), espectro de atividade local (Local Activity Spectrum - LAS), *Local Binary Pattern* (LBP), QCCH, análise estatística de informações estruturais (*Statistical Analysis of Structural Information* - SASI), decomposição de pirâmide dirigível, Unser. Outros três métodos utilizados, também baseados no princípio de cor e metadados, foram denominados de *color*, *meta* e *gray*.

A união de diferentes características pode proporcionar melhores resultados ao classificador (PENATTI; VALLE; TORRES, 2012), portanto todos os métodos de extração

de características foram associados em um algoritmo  $n^2$ , ou seja, HOG + LBP, HOG + QCCH, HOG + LBP + QCCH, de forma que todas as combinações possíveis foram avaliadas.

Devido ao elevado tempo de execução, esse experimento foi executado uma única vez para o tamanho de fragmento 30x30 *pixels*. Para outros tamanhos, foram avaliados as melhores combinações entre os extratores de características.

Alguns métodos não puderam extrair as características de alguns fragmentos devido as suas reduzidas dimensões (5x5 *pixels*), portanto, os fragmentos foram rotacionados em todos os eixos e unidos ao fragmento original para ampliar seu tamanho. Assim, os fragmentos de 5x5 tornaram-se 10x10 *pixels*. A essa técnica dá-se o nome de *augmentation* (Subseção 3.4.2) e permitiu a obtenção das informações dos fragmentos em questão.

Por fim, o resultado gerado pelas técnicas de classificação foram utilizados para avaliar os métodos de extração de características.

## 5.3 Classificação

A seguir são detalhados os experimentos relacionados ao treinamento e classificação das técnicas de AM.

### 5.3.1 Treinamento

Para aplicar uma técnica de AM supervisionada, torna-se necessário a classificação das imagens entre floresta / ausência de floresta com o intuito de criar o conhecimento dos modelos computacionais. Esse processo de classificação foi efetuado manualmente com o auxílio de um sistema de informações geográficas (QGis).


Basicamente, foram selecionadas e analisadas aleatoriamente no QGis, uma quantidade considerável de imagens de SR que fundamentaram a aprendizagem do classificador (Figura 25). Posteriormente, simulando o processo no qual a imagem é fragmentada, uma malha quadriculada foi projetada sobre essas figuras para dividi-las em várias partes conforme apresentado na Figura 26. Os fragmentos que eram visivelmente regiões de interesse e não possuíam ambas as classes dentro da mesma parte foram então classificados em 0 ou 1, sendo 0 para ausência de florestas e 1 a presença delas. A Figura 27 contém as coordenadas de um fragmento aleatório da Figura 26, bem como a classe atribuída manualmente a ela.

Para as fases de treinamento e validação dos modelos, foram classificados 17.535 fragmentos de imagens de SR manualmente, sendo 6.406 da classe positiva (floresta) e 11.129 da classe negativa (ausência de floresta). Posteriormente, as características foram extraídas e utilizadas pelas técnicas de AM. Esse desbalanceamento gerado foi mantido

Figura 25: Imagem de SR selecionada aleatoriamente.



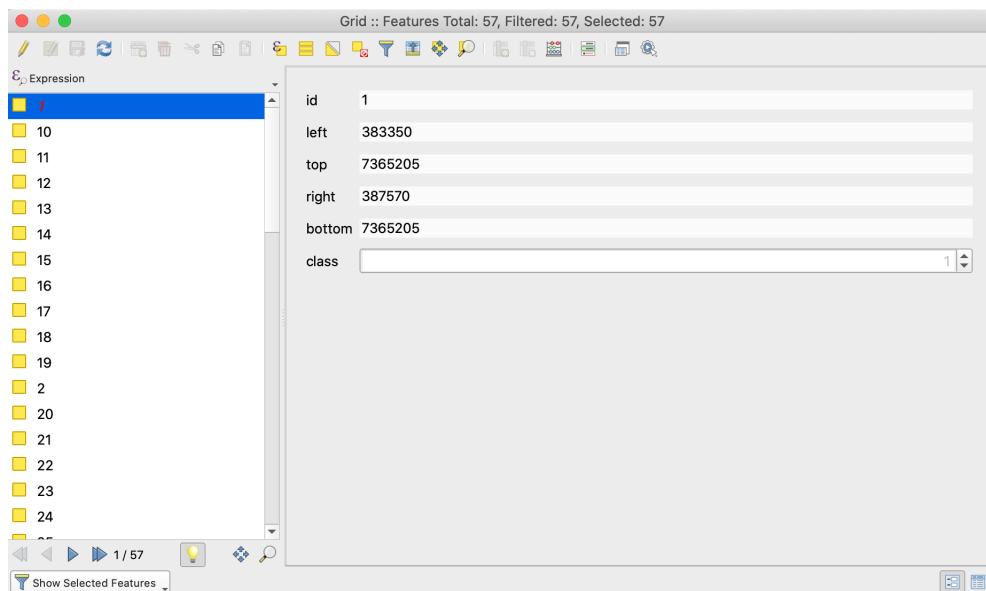
Figura 26: Malha aplicada sobre uma imagem de SR.



Fonte: elaborada pelo autor.

Fonte: elaborada pelo autor.

Figura 27: Informações retiradas de um fragmento aleatório.



Fonte: elaborada pelo autor.

durante a etapa de treinamento dos modelos de AM pois refletem as características da região estudada cuja a presença de áreas sem vegetação são em maior quantidade.

O tamanho do fragmento considerado na [Figura 26](#) é igual a 30x30 *pixels*, entretanto, esse procedimento de classificação manual ocorreu duas vezes. A primeira foi realizada para o conjunto de imagens da constelação RapidEye com tamanho de 30x30 *pixels* que posteriormente foram derivados para fragmentos de 5x5 *pixels* através da divisão de cada parte em 36 novos fragmentos. A segunda foi estabelecida para as imagens do satélite CBERS 4 com tamanho de 5x5 *pixels*.

A fim de incrementar a sensibilidade da técnica de AM e portanto, a sensibilidade do sistema de sugestão de áreas degradadas, os rótulos 0 e 1 gerados para uso no treinamento do classificador se diferenciaram do resultado obtido pelo método SAVI, pois são identificados como floresta e não floresta, ou seja, vegetações rasteiras são consideradas como não florestas.

Após o processo de rotulação dos fragmentos das imagens de SR, os modelos de classificação puderam ser construídos e avaliados.

### 5.3.2 Algoritmos

A tarefa de classificação pode ser executada por uma quantidade considerável de técnicas de AM. Dentre as mais comuns utilizadas para o problema em análise, estão as técnicas de SVM ([ZAKI et al., 2020](#); [JÚNIOR, 2018](#)) e RNA ([MAYFIELD et al., 2020](#); [LEAL; MIGUEL; MATRICARDI, 2020](#)), as quais foram selecionadas para esse trabalho por apresentarem grande capacidade de generalização para o problema investigado.

A dimensão dos vetores ( $f$ ) que são considerados entradas para os modelos de classificação dependem de quais métodos de extração de recursos são avaliados no momento, ou seja, o HTD possui 24 recursos e o LBP possui apenas 10, conseqüentemente, se a entrada for HTP + LBP, o tamanho da entrada terá 34 características. Essa dimensão influencia os valores dos hiper-parâmetros analisados para cada algoritmo avaliado, por exemplo, a RNA foi avaliada com uma, duas e três camadas ocultas, cada qual tem uma ou duas vezes o número de neurônios na camada de entrada. Logo, para o caso descrito, as camadas ocultas possuem 34 e 68 neurônios. Os hiper-parâmetros do SVM tiveram suas variações estabelecidas da seguinte forma: o *kernel* foi avaliado com as funções *Radial Basis Function* (RBF) e polinomial, o coeficiente do *kernel* também teve sua variação baseada no tamanho do vetor de entrada  $\{ \frac{1}{0.5f}, \frac{1}{f}, \frac{1}{2f} \}$  e o custo ( $C$ ) variou entre 0,5, 1, 2.

A validação dos métodos de classificação foi realizada por meio do método de re-amostragem de validação cruzada estratificada conforme descrito na [Seção 3.4](#). O valor de  $k$  adotado nos experimentos realizados foi igual a 10.

Devido ao problema ser binário (floresta ou ausência de floresta), medidas como a

*Area Under the Curve* (AUC) basearam o estudo, entretanto, medidas comumente usadas para a avaliação de classificadores, como precisão e revocação, geradas a partir da matriz de confusão, também foram empregadas neste trabalho.

Após esse processo de validação, o melhor modelo de classificação foi selecionado e treinado com todos os fragmentos rotulados anteriormente para que pudesse ser aplicado no método proposto para uma nova imagem de outra região da Mata Atlântica. Sendo assim, os resultados da classificação são apresentados na próxima seção.

Finalmente, os algoritmos responsáveis por executar esses experimentos foram desenvolvidos em Python na versão 3.7 com o auxílio da biblioteca *scikit-learn*<sup>3</sup> (PEDREGOSA et al., 2011).

## 5.4 Segmentação

As segmentações intermediárias que construíram a abordagem colaborativa desenvolvida permitiram a identificação de áreas de possíveis desmatamentos. Sua avaliação ocorreu de forma qualitativa e quantitativa.

Durante a avaliação qualitativa foi levado em consideração a suavidade e acurácia na definição das bordas e a capacidade dos métodos de segmentação em detectar áreas de vegetação e solo exposto.

A análise qualitativa também foi realizada na comparação das regiões identificadas como áreas degradadas com as infrações de desmatamento autuados pela Polícia Militar Ambiental do Estado de São Paulo. Para isso, foram analisados visualmente 19 autuações com uma área mínima de 97m<sup>2</sup> identificando falhas e acertos.

Os métodos de avaliação LCE e GCE compuseram a avaliação quantitativa e foram escolhidos devido ao fato de permitir a comparação das diferentes segmentações em relação ao *ground truth*, identificando os melhores resultados em ambas as direções. Para auxílio no processo de comparação dos resultados, também foi aplicado a métrica Kappa Index que permitiu a avaliação da classificação das imagens e não somente a segmentação.

A comparação com o método desenvolvido por Hislop et al. (2019), cujo estudo foi a base para essa abordagem colaborativa, não foi realizada devido a insuficiência de dados e algoritmos providos dos autores, portanto, para que essa comparação fosse realizada seria necessário implementar o algoritmo descrito por Hislop et al. (2019) para aplicá-lo aos dados selecionados neste estudo e o tempo disponível para implementar e realizar todos os experimentos era reduzido.

---

<sup>3</sup> <https://scikit-learn.org>





## 6 RESULTADOS

Nesta seção são apresentados os resultados dos métodos de segmentação de acordo com a proposta descrita no [Capítulo 4](#) e os experimentos do [Capítulo 5](#). Primeiramente, estão expostos os resultados referentes aos métodos de classificação ([Seção 6.1](#)), seguidos pelos métodos de segmentação ([Seção 6.2](#)) e análise de áreas degradadas ([Seção 6.3](#)).

### 6.1 Classificação

A acurácia dos modelos de classificação é crucial para o sucesso do segmentador híbrido proposto nesse estudo, portanto, nessa seção, o desempenho preditivo das técnicas de AM é apresentado e discutido.

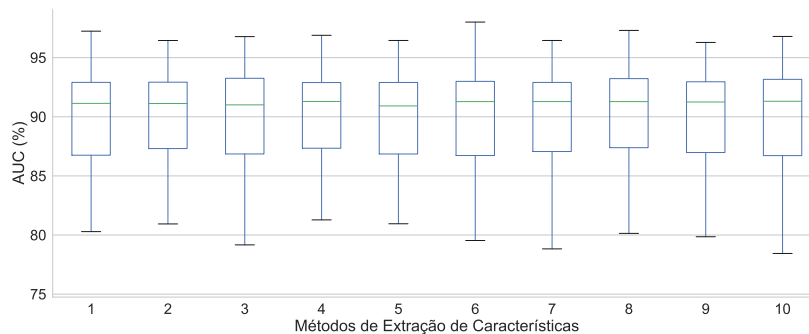
#### 6.1.1 RapidEye

Preliminarmente, é avaliado a influência dos diferentes métodos de extração de características na acurácia dos modelos de AM para as imagens adquiridas da constelação de satélites RapidEye. A [Figura 28](#) apresenta o gráfico *boxplot* da medida AUC para as dez melhores combinações de descritores em ordem crescente do valor médio, independentemente da técnica de AM e dos valores dos seus hiper-parâmetros. Na [Tabela 3](#) são descritas as combinações de descritores para cada ponto do eixo  $x$  desse gráfico com seus respectivos resultados médios. Nesses experimentos utilizou-se fragmentos de  $30 \times 30$  *pixels*.

O subconjunto de resultados apresentados na [Figura 28](#) possui um desempenho geral significativo. Ao todo, sumarizando todas as partições, hiper-parâmetros e técnicas avaliadas das dez combinações de descritores foram 2.100 resultados, cuja a média permaneceu igual a 90,04% com desvio padrão de 3,85% e mediana de 91,23%. Entretanto, os resultados obtiveram uma variância considerável. Os valores de mínimo e máximo foram de 75,85% e 98,00% respectivamente, o que demonstra a sensibilidade da técnica aplicada.

A partir da análise dos métodos de extração de características em conjunto com as técnicas de AM, observou-se que o método de descritor Gist se destacou em comparação aos demais. Esse fato pode ser explicado devido ao descritor “fornecer uma holística global representando a estrutura espacial dominante de uma cena” ([PENATTI; VALLE; TORRES, 2012](#)). A [Figura 29](#) apresenta a média para os resultados cujo o método de extração Gist está presente no conjunto de extratores e para o caso onde o mesmo não aparece. Os resultados foram de 0,89 e 0,62, respectivamente, evidenciando uma significativa diferença. Ademais, o desvio padrão da coluna onde a técnica em questão está presente é de 0,003, enquanto na coluna ausente, o desvio é de 0,030. Individualmente o método também

Figura 28: Gráfico *boxplot* com os 10 melhores resultados dos métodos de extração de características para medida AUC.



Fonte: elaborada pelo autor.

Tabela 3: Representação dos métodos de extração de características combinados apresentados na Figura 28.

Índice	Métodos de Extração	AUC Médio (%)
1	sasi; hog; gist; las; qcch; unser	90,09 ± 3,84
2	steerable; sasi; hog; gist; las; qcch; unser	90,07 ± 3,81
3	htd; sasi; hog; gist; las; lbp; qcch	90,05 ± 3,88
4	htd; steerable; sasi; hog; gist; las; lbp; qcch; unser	90,04 ± 3,87
5	htd; sasi; hog; gist; las; lbp; qcch; unser	90,04 ± 3,82
6	htd; steerable; sasi; hog; gist; las; unser	90,04 ± 3,93
7	htd; sasi; hog; gist; las; qcch; unser	90,04 ± 3,83
8	sasi; hog; gist; las; lbp; qcch; unser	90,03 ± 3,85
9	htd; sasi; hog; gist; las; qcch	90,01 ± 3,74
10	sasi; hog; gist; las; unser	90,00 ± 4,03


Fonte: Elaborada pelo autor.

alcançou um resultado de 0,89, o que admite ignorar as outras técnicas para reduzir o tempo de processamento durante a tarefa de classificação.

Na Figura 30 e Figura 31 são apresentados os gráficos de média para os dez melhores resultados ordenados crescentemente adquiridos com a RNA e o SVM, respectivamente. Da mesma forma, a Tabela 4 e a Tabela 5 caracterizam os métodos de descrição utilizados para cada barra de ambos os gráficos na devida ordem.

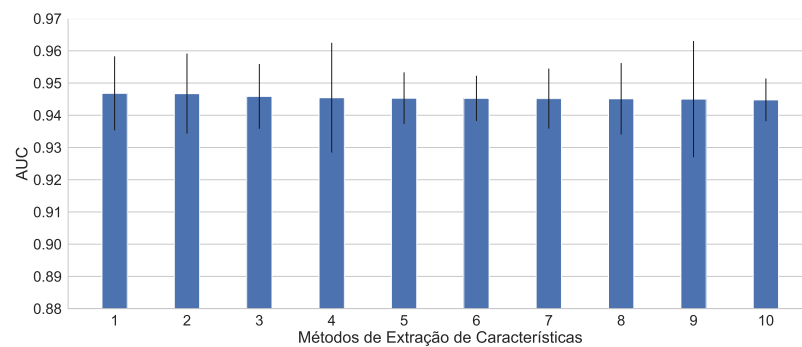
Os gráficos indicam uma incipiente superioridade garantida pela técnica RNA quando comparada com o SVM, pois a diferença média entre os 10 melhores resultados de cada técnica foi de aproximadamente 0,04. Essa superioridade pode ser visualizada comparando os resultados dos classificadores empregados no melhor conjunto de características encontrado: sasi; hog; gist; las; qcch; unser (Tabela 3). Os valores para a RNA se mantiveram entre 0,90 e 0,97 enquanto os valores obtidos pelo SVM permaneceram entre 0,80 e 0,95. Além disso, a RNA evidenciou menor sensibilidade aos hiper-parâmetros

Figura 29: Ferramenta de automatização executando a rotina.



Fonte: elaborada pelo autor.

Figura 30: AUC para os 10 melhores resultados obtidos pela RNA.



Fonte: elaborada pelo autor.


Tabela 4: Representação dos métodos de extração de características combinados apresentados na Figura 30.

Índice	Métodos de Extração
1	htd; sasi; hog; gist; qcch
2	steerable; sasi; hog; gist; lbp; qcch
3	steerable; sasi; hog; gist; qcch
4	htd; hog; gist; lbp; qcch; unser
5	htd; steerable; sasi; hog; gist; las; lbp
6	htd; steerable; sasi; hog; gist; qcch
7	htd; sasi; hog; gist; lbp
8	sasi; hog; gist; lbp; qcch; unser
9	steerable; sasi; hog; gist; lbp
10	htd; steerable; sasi; hog; gist; lbp; qcch

Fonte: Elaborada pelo autor.

obtendo um desvio padrão médio de 0,01, equivalente a aproximadamente metade do desvio padrão médio obtido pelo SVM (0,03). Para verificar se a diferença entre as duas técnicas

Figura 31: AUC para os 10 melhores resultados obtidos pelo SVM.



Fonte: elaborada pelo autor.

Tabela 5: Representação dos métodos de extração de características combinados apresentados na Figura 31.

Índice	Métodos de Extração
1	steerable; sasi; hog; gist; las; qcch; unser
2	sasi; hog; gist; las; lbp; qcch; unser
3	sasi; hog; gist; las; qcch; unser
4	htd; sasi; hog; gist; las; lbp; qcch; unser
5	htd; sasi; hog; gist; las; lbp; qcch
6	htd; sasi; hog; gist; las; qcch; unser
7	htd; steerable; sasi; hog; gist; las; unser
8	htd; steerable; sasi; hog; gist; las; lbp; qcch; unser
9	htd; sasi; hog; gist; las; qcch
10	htd; steerable; sasi; hog; gist; las; lbp; qcch

Fonte: Elaborada pelo autor.

são significativas, o teste de Wilcoxon com 0,05 de significância foi aplicado. Concluí-se que a hipótese nula de que os algoritmos possuem desempenho preditivo semelhante não pode ser rejeitada com  $\alpha=0,05$ .

### 6.1.2 CBERS 4

Os melhores conjuntos de extratores de características selecionados no experimento descrito na Subseção 6.1.1 foram então analisados para as imagens do satélite CBERS 4 com tamanho do fragmento igual a  $5 \times 5$  pixels. A Figura 32 apresenta o *boxplot* com os dez melhores resultados do experimento e a Tabela 6 seus respectivos métodos de extração de características.

A mediana e média dos resultados foram superiores a 98% em todos os casos, o que demonstra que o estudo pode ser aplicado em outros conjuntos de imagens com igual ou superior eficácia. Também é possível inferir que o tamanho de  $5 \times 5$  pixels juntamente

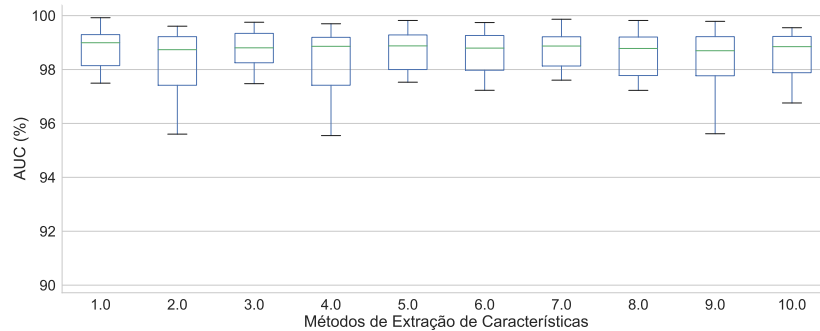
com a técnica de *augmentation*, conforme citado no [Capítulo 5](#), provavelmente auxiliaram na tentativa de aumentar os resultados da segmentação por meio de uma abordagem colaborativa.

Tabela 6: Representação dos métodos de extração de características combinados apresentados na [Figura 32](#).

Índice	Métodos de Extração
1	htd, steerable, sasi, hog, ccom, gist, lbp, unser, color, gray
2	htd, steerable, sasi, hog, ccom, gist, lbp, unser, meta, color
3	gist, color, gray
4	gist, meta, color
5	htd, steerable, sasi, hog, gist, lbp, unser, color, gray
6	gist, meta, gray
7	htd, steerable, sasi, hog, gist, lbp, unser, meta, color
8	htd, steerable, sasi, hog, gist, las, lbp, qcch, meta, color
9	htd, steerable, sasi, hog, gist, las, lbp, qcch, color, gray
10	htd, steerable, sasi, hog, gist, las, lbp, unser, color, gray

Fonte: Elaborada pelo autor.

Figura 32: Gráfico *boxplot* com os 10 melhores resultados dos métodos de extração de características para medida AUC com imagens do satélite CBERS 4.



Fonte: elaborada pelo autor.


Embora os resultados mostrados pela [Figura 32](#) sejam promissores, a segmentação efetuada pelo classificador não apresenta bordas suaves. Esse efeito pode ser explicado devido aos fragmentos usados pela técnica de AM possuírem tamanhos de  $5 \times 5$  *pixels* que resultam em bordas quadradas. Em outras palavras, quanto menor o tamanho de um fragmento, mais suaves seriam os limites. No entanto, não é possível extrair informações de fragmentos menores que  $5 \times 5$  *pixels* conforme descrito na [Subseção 3.4.2](#). A segmentação por meio de um classificador aplicado sobre a [Figura 33](#) dá origem ao resultado demonstrado na [Figura 34](#) e na [Figura 35](#) evidenciando essa desvantagem.

Figura 33: Imagem original adquirida pelo satélite CBERS 4.




Fonte: elaborada pelo autor.

Figura 34: Os resultados da técnica de classificação revelam limites quadrados quando comparados com a imagem original. As regiões verde e marrom representam regiões de florestas e ausência de florestas respectivamente.



Fonte: elaborada pelo autor.

Figura 35: Figura 34 projetada sobre a Figura 33.



Fonte: elaborada pelo autor.


## 6.2 Segmentação

Para estudar os efeitos propagados por cada método de segmentação empregado na abordagem colaborativa desenvolvida, esta seção foi estruturada da seguinte maneira. A [Subseção 6.2.1](#) analisa e compara os resultados gerados qualitativamente e a [Subseção 6.2.2](#) mostra a análise quantitativa das segmentações das imagens.

### 6.2.1 Análise qualitativa

A análise qualitativa a seguir foi realizada usando como base a região capturada pelo sensor CBERS 4 no ano de 2017 do município de Arealva-SP, com um tamanho de 2km<sup>2</sup>, apresentada na [Figura 36](#). Essa análise estende-se da [Figura 37](#) até a [Figura 47](#) em uma região que foi alvo de desmatamento no ano de 2017 posteriormente a aquisição da imagem pelo satélite.

Figura 36: Imagem original adquirida do CBERS 4 em 2017.



Fonte: elaborada pelo autor.

A seguir, são apresentados os resultados dos métodos de segmentação (SAVI, multi-escala, classificação e *marker-controlled watershed-based*) e da abordagem colaborativa desenvolvida.

A segmentação multi-escala ([Figura 37](#)) é um método baseado em bordas que não classifica as regiões sob o contexto da ausência e presença de floresta. A probabilidade de distinguir as regiões de interesse em sua forma correta também é reduzida, pois o método é caracterizado por criar uma super-segmentação (*over-segmentation*) conforme mencionado na [Subseção 3.2.2](#). Seu resultado gera várias regiões com base em cores e formas, no entanto, mesmo na escala mais fina, que contém todas as regiões encontradas pelo método, é possível visualizar inconsistências. Baseada na diferença de coloração (solo exposto em marrom e vegetação em verde), a área destacada pelo polígono laranja na [Figura 38](#) indica uma região que deveria ter sido segmentada e não foi.

Os polígonos vermelhos e amarelos fazem referências aos delineamentos das bordas geradas. Os retângulos vermelhos da [Figura 38](#) indicam regiões que obtiveram um contorno aquém do esperado e demonstram uma desvantagem do método ao lidar com objetos menores como estradas ou árvores. Em contrapartida os polígonos amarelos demonstram a acurácia ao delimitar regiões maiores de florestas.

Figura 37: Escala mais fina gerada pelo método multi-escala.



Fonte: elaborada pelo autor.

Figura 38: Resultado do método multi-escala plotado sobre a figura original.



Fonte: elaborada pelo autor.

O resultado do método *marker-controlled watershed-based* (Figura 39) apresentou seis regiões independentes. Ainda que o método não rotule os segmentos criados entre floresta e não floresta, estabelece uma relação entre regiões semelhantes desconectadas. Por exemplo, a região amarela aparece em várias partes da imagem sem que exista uma conexão entre estas e, ao traçar a segmentação sobre a imagem original (Figura 40), é possível visualizar o segmento como uma área de floresta. Entretanto, cinco das regiões resultantes do método serão classificadas como não floresta posteriormente e poderiam ser segmentadas como um único segmento.


O método obteve um resultado de segmentação considerável devido a boa precisão no delineamento das bordas para segmentos maiores (indicado nos retângulos amarelos) e menores (polígono azul), no entanto, não demonstrou sensibilidade para detectar uma região de possível mata rasteira (retângulo laranja). Além disso, as áreas em vermelho destacam os equívocos realizados pelo segmentador.

A Figura 41 é o resultado da segmentação criada pelo método SAVI, um índice com variância de -1 a 1 representado na Figura 42 por uma escala de cores, onde quanto mais intenso é o tom de vermelho, menor é a quantidade de plantas e quanto mais verde, maior é a quantidade de vegetação ou mais saudável está.

A segmentação criada pelo índice apresenta a vantagem quando comparado com o método *marker-controlled watershed-based* de gerar apenas dois tipos de regiões: floresta e ausência de floresta. Ela também obteve maior acurácia ao demarcar área de vegetação rasteira indicada na cor laranja, no entanto, é possível concluir que o método possui instabilidade para criar bordas, pois por vezes cria limites acurados (regiões amarelas) e



Figura 39: Resultado do método *marker-controlled watershed-based*.



Fonte: elaborada pelo autor.

Figura 40: Resultado do método *marker-controlled watershed-based* plotado sobre a figura original.



Fonte: elaborada pelo autor.

em outras, os limites extrapolam as regiões reais na imagem (regiões vermelhas).

Devido a imprecisão do limiar aplicado para selecionar os segmentos com classe 1 (floresta) dos segmentos com classe 0 (solo exposto) discutidos no [Capítulo 3](#), o método comete erros ao classificar algumas áreas, cujo o valor do índice estão próximos ao limite. Esse fato ficou evidenciado pelos polígonos em branco.

A respeito dos resultados gerados pela técnica de AM ([Figura 44](#)), pode-se visualizar áreas demarcadas em amarelo na [Figura 45](#) que indicam a falta de suavidade ao delinear as bordas das regiões. Esse problema poderia ter sido contornado pelo deslocamento dos fragmentos na imagem. Em outras palavras, supondo uma imagem de  $100 \times 100$  pixels e ao invés de atribuir a todos os pixels do fragmento que se inicia na posição  $25 \times 25$  o valor da classificação dessa parte, poderia ser feita a classificação de um fragmento iniciando-se na posição  $25 \times 25$ , outra na  $26 \times 25$ ,  $27 \times 25$  e assim sucessivamente. Assim, o resultado de cada pixel, seria a média das classificações a que este pertenceu. Mesmo assim, a desvantagem é compensada pela acurácia considerável em definir as áreas menores e maiores entre floresta e não floresta (polígono azul).


O retângulo vermelho evidencia a diferença com a região centro-direita no resultado apresentado pelo método SAVI ([Figura 42](#)) e ocorreu devido à vegetação rasteira. A análise é considerada como negativa para o resultado devido a possibilidade de existir uma vegetação nativa naquela região, entretanto, o classificador identifica corretamente a área de vegetação rasteira (retângulo laranja) como floresta e a região branca como não floresta. Conclui-se que essas amostras deveriam ser adicionadas ao conjunto de treinamento do modelo para então refletir no resultado da segmentação.

Figura 41: Resultado do método SAVI classificada entre floresta (verde) e não floresta (marrom).




Fonte: elaborada pelo autor.

Figura 42: Resultado do método SAVI em escala de cores.



Fonte: elaborada pelo autor.

Figura 43: Resultado do método SAVI plotada sobre a imagem original.




Fonte: elaborada pelo autor.

Figura 44: Resultado da técnica de AM classificada entre floresta (verde) e não floresta (marrom).



Fonte: elaborada pelo autor.

Figura 45: Resultado da técnica de AM plotada sobre a imagem original.



Fonte: elaborada pelo autor.

Após a análise dos quatro segmentadores, o método proposto na [Seção 4.3](#) foi executado e deu origem a [Figura 46](#). Ao analisar qualitativamente esse resultado desenhado sobre a imagem original ([Figura 47](#)), é possível visualizar que a abordagem colaborativa obteve uma melhor acurácia quando comparado com os outros métodos individualmente.

Os retângulos evidenciados na [Figura 47](#) destacam as vantagens e desvantagens apresentadas pelo método. Os polígonos em azul indicam que as bordas suaves criadas pelo método *marker-controlled watershed-based* na [Figura 39](#) foram mantidas e as bordas quadradas geradas pela técnica de AM ([Figura 45](#)) foram desprezadas tanto para objetos pequenos, quanto para os grandes. A indicação em laranja reflete a média da colaboração entre os resultados na [Figura 38](#), [Figura 43](#) e [Figura 45](#). As marcações em branco e vermelho mostram erros proveniente do método SAVI ao classificar áreas em cor verde na imagem real como floresta, porém essas falhas no resultado da [Figura 47](#) são menores em área.


A [Tabela 7](#) exhibe as medidas de LCE, GCE e Kappa Index para cada método empregado na [Figura 36](#). O método de classificação obteve um erro acima do esperado devido as suas bordas quadradas. Por fim, mesmo a [Figura 39](#), [Figura 43](#) e a [Figura 47](#) alcançarem valores de LCE próximos, pode-se eleger o resultado gerado pela abordagem colaborativa superior aos outros devido a comparação dos resultados de LCE, GCE e Kappa Index analisados juntos.

Figura 46: Resultado da estrutura colaborativa empregada classificada entre floresta (verde) e não floresta (marrom).



Fonte: elaborada pelo autor.

Figura 47: Resultado da estrutura colaborativa empregada plotada sobre a imagem original.



Fonte: elaborada pelo autor.

Tabela 7: Métricas de LCE, GCE e Kappa Index para cada método de segmentação aplicado.

Método de Segmentação	LCE (%)	GCE (%)	Kappa
Multi-escala	17,12	17,43	0,54
<i>Marker-controlled watershed-based</i>	7,47	14,24	0,59
Técnica de AM	11,77	16,35	0,65
SAVI	7,38	14,98	0,62
Abordagem colaborativa de segmentação	7,40	12,78	0,70

Fonte: Elaborada pelo autor.


## 6.2.2 Análise quantitativa

A Tabela 8 apresenta os resultados de LCE, GCE e Kappa Index para o conjunto com todas as imagens analisadas no estudo.

Em razão do conceito dos métodos de avaliação empregados para validar as segmentações descrito na Subseção 3.5.2, se uma região gerada por um segmentador estiver contida ou conter a região gerada pelo *ground truth* o erro será 0. Sendo assim, as métricas desconsideram casos como os indicados pelas setas em cinza na Figura 48. Além do mais, a métrica LCE e GCE avaliam o delineamento dos segmentos não considerando a classificação destes. A métrica de avaliação Kappa Index é responsável por auxiliar nesse comparação.

Comparando os resultados de ambas as métricas, é possível visualizar um erro elevado para o segmentador multi-escala, bem como um desvio padrão de mesma proporção. Isso é justificado pela super-segmentação realizada por ele e como esse método foi aplicado

Figura 48: Indicação de erro zero devido as regiões estarem contidas uma nas outras.



Fonte: elaborada pelo autor.

com o intuito de delinear todas as regiões da imagem, esse era um comportamento esperado.

As bordas quadradas geradas pelos resultados da técnica de AM corroboram para os erros elevados apresentados, porém a vantagem são os resultados consideráveis da classificação gerada pela técnica, ou seja, a possibilidade de classificar as regiões é considerado superior aos erros elevados.

A abordagem colaborativa desenvolvida, e os métodos SAVI e *marker-controlled watershed-based* apresentaram leves diferenças nos resultados e nos desvios da métrica LCE. Isso indica uma afinidade entre essas segmentações, além de evidenciar a semelhança dos métodos em comparação com o *ground truth*.

A métrica GCE alcançou um erro maior e isso demonstra que ao avaliar a imagem sempre na mesma direção a performance dos métodos são piores conforme descrito no [Capítulo 3](#). Embora os três métodos tenham valores próximos (método desenvolvido, SAVI e *Marker-controlled watershed-based*), a abordagem colaborativa possui um resultado e desvio padrão relativamente menor.

Pela métrica Kappa Index, é possível identificar que os métodos de segmentação que não atribuem classificação por padrão (multi-escala e *Marker-controlled watershed-based*) apresentaram resultados menores. A segmentação gerada pelo SAVI e pela abordagem colaborativa obtiveram resultados moderadamente superior a técnica de classificação, entretanto, os resultados foram instáveis com desvios padrões superiores a 0,11.

Sendo assim, é possível concluir que ao unir os resultados dos vários métodos estudados em uma abordagem colaborativa, o resultado final é promissor e auxiliará na busca por áreas degradadas. Contudo, também é possível identificar que os resultados

Tabela 8: Métricas LCE, GCE e Kappa Index para cada método de segmentação aplicado.

Método de Segmentação	LCE	GCE	Kappa
Multi-escala	11,20 ± 6,57	11,78 ± 6,72	0,50 ± 0,15
<i>Marker-controlled watershed-based</i>	6,64 ± 4,03	11,67 ± 7,21	0,53 ± 0,18
Técnica de AM	9,36 ± 5,54	15,22 ± 8,40	0,60 ± 0,11
SAVI	5,68 ± 4,33	11,20 ± 8,71	0,65 ± 0,21
Abordagem colaborativa de segmentação	5,87 ± 4,18	10,04 ± 7,91	0,66 ± 0,18

Fonte: Elaborada pelo autor.

do segmentador gerado pelo SAVI se tornam atraentes quando é considerado o tempo de execução da abordagem colaborativa. Portanto, com o objetivo de alcançar um resultado mais expressivo é aconselhável o uso da abordagem colaborativa, outrora se o objetivo for velocidade, deve-se aplicar o método SAVI.

O [Apêndice B](#) contém outras imagens resultantes dos métodos de segmentação para aprofundar as análises dessas figuras.

### 6.3 Desmatamento


Após segmentar a [Figura 49](#) e a [Figura 50](#), ambas referentes a mesma região (Fernandópolis-SP) capturadas em 2016 e 2019 respectivamente, os resultados da abordagem colaborativa ([Figura 51](#) e [Figura 52](#)) foram comparados com o objetivo de encontrar áreas de possível desmatamento e assim originaram a [Figura 53](#).

A [Figura 54](#) foi estabelecida pelos profissionais da Polícia Militar Ambiental do Estado de São Paulo conforme descrito no [Capítulo 5](#) e permitiu a comparação com a [Figura 53](#) para avaliar o resultado gerado pela pesquisa. A discrepância entre as duas figuras, como a demarcada pelo polígono em branco, pode ser explicada devido a área desmatada ilegal encontrada por especialistas não ter sido investigada nas mesmas imagens ou períodos da [Figura 49](#) e da [Figura 50](#) pois os dados da polícia são baseados em demarcação *in loco* ao invés da demarcação com uso de imagens de SR.

Uma desvantagem do método desenvolvido está representada no polígono em amarelo na [Figura 53](#) que indica uma região onde houve uma degradação florestal que possivelmente ocorreu em uma região permitida e sendo assim, não foi delimitada pela fiscalização.

Além do mais, a procura por desmatamento é sensível a “ruídos”, como indicado pelo quadrado azul, no qual um pequeno conjunto de *pixels* foi encontrado como desmatamento, o que sugere uma falha na classificação. Outrora, a abordagem colaborativa sugeriu a região identificada pela polícia como degradada, o que indica que em um cenário real, onde o sistema estivesse sendo executado constantemente, essa seria uma região evidenciada para fiscalização.

Figura 49: Imagem original em 2016.




Fonte: elaborada pelo autor.

Figura 51: Resultado da abordagem colaborativa em 2016.



Fonte: elaborada pelo autor.

Figura 50: Imagem original em 2019.




Fonte: elaborada pelo autor.

Figura 52: Resultado da abordagem colaborativa em 2019.




Fonte: elaborada pelo autor.

Figura 53: Desmatamento encontrado entre as imagens de 2016 e 2019 pela abordagem colaborativa.



Fonte: elaborada pelo autor.

Figura 54: Desmatamento encontrado em 2018 pela Polícia Militar Ambiental do Estado de São Paulo.



Fonte: elaborada pelo autor.

Outros comparações entre as autuações geradas pela polícia e os resultados da abordagem colaborativa podem ser encontrados no [Apêndice B](#).

## 6.4 Regeneração

Similar a técnica aplicada para identificar as regiões desmatadas, a comparação entre duas imagens permite encontrar áreas regeneradas, ou seja, regiões que foram classificadas como solo exposto e posteriormente, nas imagens recentes, receberam a classificação de vegetação.


A [Figura 55](#) e a [Figura 56](#) foram capturadas em 2016 e 2018 pelo satélite CBERS 4 no município de Colômbia-SP e deram origem através da abordagem colaborativa a [Figura 57](#) e a [Figura 58](#) respectivamente.

É possível constatar que os resultados produzidos pela abordagem desenvolvida apresenta uma segmentação considerável ao compará-los com as imagens originais. A subtração dos resultados evidenciando a regeneração é indicada na [Figura 59](#) pelos polígonos de cor alaranjada.

Assim como descrito na [Seção 6.3](#), a identificação de regeneração também é possível em cenários reais com confiança considerável, o que poderia auxiliar as autoridades a monitorar o reflorestamento em casos em que são obrigados pela justiça.



Figura 55: Imagem original em 2016.




Fonte: elaborada pelo autor.

Figura 57: Resultado da abordagem colaborativa em 2016.



Fonte: elaborada pelo autor.

Figura 56: Imagem original em 2018.




Fonte: elaborada pelo autor.

Figura 58: Resultado da abordagem colaborativa em 2018.



Fonte: elaborada pelo autor.

Figura 59: Identificação de áreas regeneradas entre a Figura 55 e a Figura 56



Fonte: elaborada pelo autor.

# Conclusão

As florestas exercem considerável importância ambiental, social e econômica. Sua preservação garante o equilíbrio ecológico, previne erosões, evita enchentes e mantém os níveis de carbono equilibrado. Todavia, as atividades agrícolas, exploração excessiva dos recursos naturais, incêndios e urbanização têm contribuído para a redução da cobertura florestal no planeta.

No Brasil, a floresta Amazônica atrai maior interesse dos pesquisadores. Contudo, os biomas de Cerrado e Mata Atlântica, que abrangem os biomas do Estado de São Paulo, sofreram com elevados níveis de desmatamentos nos últimos anos.

Na tentativa de reflorestar as áreas degradadas e evitar novos desflorestamentos, o governo brasileiro integra acordos internacionais e sanciona leis anti-desmatamento. Entretanto, apesar do sucesso de sistemas computacionais para monitoramento e identificação de desmatamento como o MapBiomas, é desconhecido o uso desses sistemas pela Polícia Militar Ambiental do Estado de São Paulo, uma vez que estes podem ser inacessíveis ou mesmo incompletos para as devidas necessidades e especificidades da Polícia paulista, dificultando a fiscalização dos órgãos encarregados dessa tarefa.

A literatura apresenta diferentes métodos e técnicas para solucionar esse problema, porém essas técnicas são apresentadas individualmente ou em abordagem híbrida padrão, ou seja, emprego de um método de segmentação baseado em linhas que gera um resultado super-segmentado e a fusão desses segmentos por meio de um método baseado em regiões. O trabalho de [Hislop et al. \(2019\)](#) é o mais próximo do estudo apresentado devido ao uso da técnica de *ensemble* (comitê) para junção de índices de vegetação e métodos de segmentação.

Nesse contexto, o presente trabalho propôs uma abordagem colaborativa entre quatro métodos de detecção de áreas degradadas e regeneradas: SAVI, técnicas de AM, método de segmentação multi-escala e o método de segmentação *marker-controlled watershed-based*. A abordagem proposta foi aplicada para segmentar imagens com 5m de resolução espacial e sugerir áreas de desmatamento no Estado de São Paulo através da comparação bitemporal dos resultados. A abordagem colaborativa realiza a combinação dos diferentes métodos de segmentação e classificação por meio de um sistema de intersecção entre regiões seguida da votação para definir a classe dessas regiões. Em outras palavras, cada *pixel* de uma região segmentada recebe um rótulo que identifica sua classe: floresta ou não floresta. Portanto, as diferentes regiões segmentadas pelos diferentes métodos são combinadas, resultando em uma única segmentação por meio de um processo de votação majoritária.

O método também possibilita a identificação de áreas regeneradas com precisão

considerável invertendo os parâmetros da comparação bitemporal, ou seja, regiões que possuíam a classificação de áreas de solo exposto e posteriormente foram identificadas como vegetação. Essa extensão da abordagem desenvolvida permite que os órgãos de fiscalização possam acompanhar os processos de reflorestamento que são determinados judicialmente.

Os resultados gerados pela aplicação da abordagem colaborativa foram comparados com as regiões fiscalizadas pela Polícia Militar do Estado de São Paulo, demarcadas com o auxílio de aparelhos de GPS, o que diminui a probabilidade de erro por subjetividade causada por processos manuais. Até o presente momento não foram encontradas outras pesquisas com o mesmo objetivo que tenham validado seus resultados com dados de fiscalização da polícia ambiental.

A primeira análise realizada foi referente às técnicas de classificação empregadas para distinguir regiões de florestas ou solos expostos. Os melhores resultados encontrados para as técnicas de AM foram superiores a 0,98 de AUC considerando fragmentos de  $5 \times 5$  *pixels* em imagens de resolução espacial de 5m. Conseqüentemente, os modelos de classificação estabelecidos com os métodos de extração de características estudados, são capazes de generalizar o conhecimento e auxiliarem durante o processo de segmentação da abordagem colaborativa.

Devido aos fragmentos empregados serem de dimensões quadradas, o método de classificação foi incapaz de criar bordas suaves. Para solucionar o problema, ao invés de classificar os fragmentos de forma fixa na imagem, deveria ter sido realizado o deslocamento destes. Portanto, a classificação de cada *pixel* seria determinada pela média de classes dos fragmentos que ele pertence.

A segunda análise empregada foi relacionada aos métodos de segmentação estudados. A abordagem colaborativa superou os resultados do segmentador SAVI na métrica GCE e se mantiveram próximos na métrica LCE. Isso reflete os resultados promissores relatados quantitativamente. Contudo, para alguns conjuntos de imagens ao invés da abordagem colaborativa ser influenciada pelos resultados positivos encontrados nos métodos que a embasam, esta foi influenciada pelos erros cometidos. Esse efeito precisa ser melhor estudado para alcançar melhores resultados.

Em geral, a abordagem colaborativa desenvolvida se mostrou eficiente durante o processo de busca por desmatamento e áreas regeneradas. A comparação das segmentações de regiões desmatadas produzidas em imagens de forma bitemporal foi promissora e refletiu em grande parte das imagens analisadas as autuações de infrações demarcadas manualmente pela Polícia Militar Ambiental do Estado de São Paulo.

Finalmente, é possível evidenciar que o trabalho apresentado pode ser de considerável importância para os órgãos de fiscalizações de desmatamento no Estado de São

Paulo, uma vez que é possível sugerir regiões com alta probabilidade de infrações.

## Trabalhos Futuros

Com o objetivo de estabelecer a continuidade do projeto, a abordagem colaborativa apresentada pode ser avaliada para conjuntos de imagens de outros biomas, a fim de ampliar a zona de abrangência. Outra linha de pesquisa, é a junção de dados provenientes de sistemas governamentais, como o SICAR, ou dados referente aos tipos de vegetação presentes nas regiões estudadas para alcançar resultados com maior acurácia.

O método proposto também foi desenvolvido com foco em uma análise bi-temporal de imagens de SR. Uma possível extensão do estudo é ampliá-lo de forma a validar as mudanças de coberturas do solo ao longo do tempo, aumentando assim a velocidade de detecção de um possível desmatamento.

Por último, é necessário a implementação de uma interface na qual o método se torne útil para órgãos de fiscalização no processo pela busca por áreas degradadas ilegalmente e áreas regeneradas.



## Referências

- ACHARD, F. et al. Determination of tropical deforestation rates and related carbon losses from 1990 to 2010. *Global Change Biology*, v. 20, n. 8, p. 2540–2554, 2014. ISSN 13652486. Citado 2 vezes nas páginas 24 e 32.
- ACHARD, F.; HANSEN, M. C. The brazilian amazon monitoring program: Prodes and deter projects. In: *Global Forest Monitoring from Earth Observation*. [S.l.]: CRC Press, 2016. p. 168–185. Citado na página 24.
- AKIYAMA, T. S.; JUNIOR, J. M.; TOMMASELLI, A. M. G. Correção geométrica de imagens cbers-4/pan com modelos generalizados usando como referência dados do sistema nacional de gestão fundiária. *Anuário do Instituto de Geociências*, v. 41, n. 2, p. 358–368, 2019. Citado na página 101.
- ARCANJO, J. S. et al. Methods for evaluating volunteers' contributions in a deforestation detection citizen science project. *Future Generation Computer Systems*, Elsevier, v. 56, p. 550–557, 2016. Citado na página 24.
- BANSKOTA, A. et al. Forest monitoring using landsat time series data: a review. *Canadian Journal of Remote Sensing*, Taylor & Francis, v. 40, n. 5, p. 362–384, 2014. Citado na página 31.
- BARBOSA, M. Sensoriamento remoto. *Processamento digital de imagens. Programa de suporte técnico à gestão de recursos hídricos-ABEAS. Curso de Especialização em Sensoriamento Remoto e SIG*. Brasília, 1998. Citado na página 36.
- BLASCHKE, T. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 65, n. 1, p. 2–16, 2010. ISSN 0924-2716. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0924271609000884>>. Citado 3 vezes nas páginas 29, 36 e 42.
- BOYD, D. S.; DANSON, F. M. Satellite remote sensing of forest resources: three decades of research development. *Progress in Physical Geography: Earth and Environment*, v. 29, n. 1, p. 1–26, 2005. Disponível em: <<https://doi.org/10.1191/0309133305pp432ra>>. Citado 2 vezes nas páginas 23 e 24.
- CASALEGNO, S. et al. Improving models of urban greenspace: from vegetation surface cover to volumetric survey, using waveform laser scanning. *Methods in Ecology and Evolution*, Wiley Online Library, v. 8, n. 11, p. 1443–1452, 2017. Citado na página 42.
- CASTELLUCCIO, M. et al. Land use classification in remote sensing images by convolutional neural networks. *arXiv preprint arXiv:1508.00092*, 2015. Citado na página 30.
- CHENG, G.; HAN, J. A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, International Society for Photogrammetry and Remote Sensing, Inc. (ISPRS), v. 117, p. 11–28, 2016. ISSN 09242716. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2016.03.014>>. Citado 2 vezes nas páginas 43 e 44.

- CROUZEILLES, R. et al. There is hope for achieving ambitious atlantic forest restoration commitments. *Perspectives in Ecology and Conservation*, Elsevier, v. 17, n. 2, p. 80–83, 2019. Citado 2 vezes nas páginas 23 e 24.
- DALLAQUA, F. B.; FARIA, F. A.; FAZENDA, A. L. Active learning approaches for deforested area classification. In: IEEE. *2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. [S.l.], 2018. p. 48–55. Citado 2 vezes nas páginas 24 e 44.
- DERIVAUX, S. et al. Watershed segmentation of remotely sensed images based on a supervised fuzzy pixel classification. In: . [S.l.: s.n.], 2006. Citado na página 37.
- DORINGA, A. et al. Comparison of two image segmentation algorithms. In: IEEE. *2010 Second International Conferences on Advances in Multimedia*. [S.l.], 2010. p. 185–190. Citado na página 46.
- EPIPHANIO, J. C. N. Cbers-3/4: características e potencialidades. In: *Proceedings of the Brazilian Remote Sensing Symposium, Curitiba, Brazil*. [S.l.: s.n.], 2011. v. 30, p. 90099016. Citado na página 101.
- FERREIRA, M. E. et al. Desmatamento no bioma cerrado: Uma análise temporal (2001 - 2005) com base nos dados modis - mod13q1. *Anais XIII Simpósio de Sensoriamento Remoto*, p. 3877–3883, 2007. Citado na página 40.
- FIELDING, A. H.; BELL, J. F. A review of methods for the assessment of prediction errors in conservation presence/absence models. *Environmental conservation*, Cambridge University Press, v. 24, n. 1, p. 38–49, 1997. Citado na página 47.
- FRANCESCHETTI, G.; LANARI, R. *Synthetic aperture radar processing*. [S.l.]: CRC press, 2018. Citado na página 36.
- GAETANO, R. et al. Marker-controlled watershed-based segmentation of multiresolution remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 53, n. 6, p. 2987–3004, 2015. ISSN 01962892. Citado 5 vezes nas páginas 30, 31, 37, 38 e 55.
- GERAIS, D. Lei nº 9.605, de 12 de fevereiro de 1998 dispõe sobre as sanções penais e administrativas derivadas de condutas e atividades lesivas ao meio ambiente, e dá outras providências. o presidente da república. 2 1998. Citado na página 23.
- GÓMEZ, C.; WHITE, J. C.; WULDER, M. A. Optical remotely sensed time series data for land cover classification: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 116, p. 55–72, 2016. ISSN 09242716. Citado na página 35.
- GOMEZ, V. et al. A long-term perspective on deforestation rates in the brazilian amazon. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 2015. Citado na página 32.
- GU, H. et al. An efficient parallel multi-scale segmentation method for remote sensing imagery. *Remote Sensing*, v. 10, n. 4, 2018. ISSN 2072-4292. Disponível em: <<http://www.mdpi.com/2072-4292/10/4/590>>. Citado na página 25.
- GUIGUES, L.; COCQUEREZ, J. P.; MEN, H. L. Scale-sets image analysis. *International Journal of Computer Vision*, Springer, v. 68, n. 3, p. 289–317, 2006. Citado 3 vezes nas páginas 25, 38 e 54.



- HAAPANEN, R. et al. Delineation of forest/nonforest land use classes using nearest neighbor methods. *Remote Sensing of Environment*, Elsevier, v. 89, n. 3, p. 265–271, 2004. Citado na página 31.
- HAGENSIEKER, R. *Mapping a Brazilian deforestation frontier using multi-temporal TerraSAR-X data and supervised machine learning*. Tese (Doutorado) — Freie Universität Berlin, 2018. Citado na página 25.
- HAMMER, D.; KRAFT, R.; WHEELER, D. Alerts of forest disturbance from modis imagery. *International journal of applied earth observation and geoinformation*, Elsevier, v. 33, p. 1–9, 2014. Citado 2 vezes nas páginas 31 e 32.
- HANSEN, M. C. et al. Humid tropical forest disturbance alerts using landsat data. *Environmental Research Letters*, IOP Publishing, v. 11, n. 3, p. 034008, 2016. Citado na página 42.
- HETHCOAT, M. G. et al. A machine learning approach to map tropical selective logging. *Remote sensing of environment*, Elsevier, v. 221, p. 569–582, 2019. Citado 2 vezes nas páginas 31 e 32.
- HISLOP, S. et al. A fusion approach to forest disturbance mapping using time series ensemble techniques. *Remote Sensing of Environment*, v. 221, p. 188 – 197, 2019. ISSN 0034-4257. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0034425718305340>>. Citado 7 vezes nas páginas 26, 33, 34, 39, 56, 69 e 89.
- HOSSAIN, M. D.; CHEN, D. Segmentation for object-based image analysis (obia): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 150, p. 115–134, 2019. Citado 3 vezes nas páginas 26, 33 e 39.
- HOSSIN, M.; SULAIMAN, M. A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process, Academy & Industry Research Collaboration Center (AIRCC)*, v. 5, n. 2, p. 1, 2015. Citado 2 vezes nas páginas 45 e 46.
- HUETE, A. R. A soil-adjusted vegetation index (savi). *Remote sensing of environment*, Elsevier, v. 25, n. 3, p. 295–309, 1988. Citado na página 40.
- JOSHI, N. et al. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Proceedings, Annual Convention - Gas Processors Association*, v. 1, p. 427–432, 2007. ISSN 00968870. Citado na página 36.
- JUDAH, A.; HU, B.; WANG, J. An algorithm for boundary adjustment toward multi-scale adaptive segmentation of remotely sensed imagery. *Remote Sensing*, v. 6, n. 5, p. 3583–3610, 2014. ISSN 2072-4292. Disponível em: <<http://www.mdpi.com/2072-4292/6/5/3583>>. Citado na página 25.
- JÚNIOR, P. R. M. *Reconhecimento em cenário aberto para diferentes classificadores*. Tese (Doutorado) — Universidade de Campinas, 2018. Citado 3 vezes nas páginas 31, 44 e 68.
- KARANTZALOS, K.; ARGIALAS, D. A region-based level set segmentation for automatic detection of man-made objects from aerial and satellite images. *Photogrammetric Engineering & Remote Sensing*, v. 75, n. 6, p. 667–677, 2009. ISSN 0099-1112.

Disponível em: <<http://essential.metapress.com/openurl.asp?genre=article&id=doi:10.14358/PERS.75.6>> Citado na página 25.

KATSUHAMA, N. et al. Discrimination of areas infected with coffee leaf rust using a vegetation index. *Remote sensing letters*, Taylor & Francis, v. 9, n. 12, p. 1186–1194, 2018. Citado na página 42.

KEMKER, R.; SALVAGGIO, C.; KANAN, C. Algorithms for semantic segmentation of multispectral remote sensing imagery using deep learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 145, p. 60–77, 2018. ISSN 0924-2716. Deep Learning RS Data. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0924271618301229>>. Citado 2 vezes nas páginas 24 e 25.

KENNEDY, R. E.; COHEN, W. B.; SCHROEDER, T. A. Trajectory-based change detection for automated characterization of forest disturbance dynamics. *Remote Sensing of Environment*, Elsevier, v. 110, n. 3, p. 370–386, 2007. Citado na página 32.

KENNEDY, R. E.; YANG, Z.; COHEN, W. B. Detecting trends in forest disturbance and recovery using yearly landsat time series: 1. landtrendr—temporal segmentation algorithms. *Remote Sensing of Environment*, Elsevier, v. 114, n. 12, p. 2897–2910, 2010. Citado na página 40.

KLINK, C. A.; MACHADO, R. B. A conservação do cerrado brasileiro. *Megadiversidade*, conservation.org, v. 1, p. 147–155, 7 2005. Citado na página 23.

KUMAR, R.; MANJUNATH, S. Performance evaluation and comparative study of color image segmentation algorithm. In: SPRINGER. *International Conference on Advanced Informatics for Computing Research*. [S.l.], 2017. p. 130–144. Citado na página 46.

KUSSUL, N. et al. Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, v. 14, n. 5, p. 778–782, 2017. ISSN 1545-598X. Citado na página 44.

LEAL, F. A.; MIGUEL, E. P.; MATRICARDI, E. A. T. Estimates of deforestation rates in rural properties in the legal amazon. *Floresta e Ambiente*, SciELO Brasil, v. 27, n. 2, 2020. Citado na página 68.

LUZ, E. F. et al. The forestwatchers: a citizen cyberscience project for deforestation monitoring in the tropics. *Human Computation*, v. 1, n. 2, p. 137–145, 2014. Citado na página 42.

MANTOVANI, M. C. et al. *Atlas dos remanescentes florestais da mata atlântica período 2016-2017*. [S.l.], 2018. Citado na página 23.

MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, Taylor & Francis, v. 39, n. 9, p. 2784–2817, 2018. Disponível em: <<https://doi.org/10.1080/01431161.2018.1433343>>. Citado na página 43.

MAYFIELD, H. et al. Considerations for selecting a machine learning technique for predicting deforestation. *Environmental Modelling & Software*, Elsevier, p. 104741, 2020. Citado na página 68.

- MENG, X. et al. Review of the pansharpening methods for remote sensing images based on the idea of meta-analysis: Practical discussion and challenges. *Information Fusion*, Elsevier, v. 46, p. 102–113, 2019. Citado na página 37.
- MICHEL, J.; YOUSSEFI, D.; GRIZONNET, M. Stable mean-shift algorithm and its application to the segmentation of arbitrarily large remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 53, n. 2, p. 952–964, Feb 2015. ISSN 0196-2892. Citado na página 25.
- MIKOŁAJCZYK, A.; GROCHOWSKI, M. Data augmentation for improving deep learning in image classification problem. In: IEEE. *2018 international interdisciplinary PhD workshop (IIPhDW)*. [S.l.], 2018. p. 117–122. Citado na página 43.
- MILLETTE, T. L. et al. The use and limits of remote sensing for analysing environmental and social change in the himalayan middle mountains of nepal. *Global Environmental Change*, v. 5, n. 4, p. 367 – 380, 1995. ISSN 0959-3780. Disponível em: <<http://www.sciencedirect.com/science/article/pii/095937809500071U>>. Citado na página 35.
- MUELLER, M.; SEGL, K.; KAUFMANN, H. Edge-and region-based segmentation technique for the extraction of large, man-made objects in high-resolution satellite imagery. *Pattern recognition*, Elsevier, v. 37, n. 8, p. 1619–1628, 2004. Citado na página 33.
- MUMFORD, D.; SHAH, J. Optimal approximations by piecewise smooth functions and associated variational problems. *Communications on pure and applied mathematics*, Wiley Online Library, v. 42, n. 5, p. 577–685, 1989. Citado na página 38.
- NAVULUR, K. *Multispectral Image Analysis Using the Object-Oriented Paradigm*. 1. ed. Boca Raton: CRC Press, 2006. Citado na página 35.
- NGUYEN, H. T. T.; DOAN, T. M.; RADELOFF, V. Applying random forest classification to map land use/land cover using landsat 8 oli. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, p. 363–367, 2018. Citado na página 30.
- OLIVA, A.; TORRALBA, A. Building the gist of a scene: The role of global image features in recognition. *Progress in brain research*, Elsevier, v. 155, p. 23–36, 2006. Citado na página 65.
- OTHMAN, M. et al. Tropical deforestation monitoring using ndvi from modis satellite: a case study in pahang, malaysia. In: IOP PUBLISHING. *IOP Conference Series: Earth and Environmental Science*. [S.l.], 2018. v. 169, n. 1, p. 012047. Citado na página 32.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Citado na página 69.
- PENATTI, O. A.; VALLE, E.; TORRES, R. d. S. Comparative study of global color and texture descriptors for web image retrieval. *Journal of visual communication and image representation*, Elsevier, v. 23, n. 2, p. 359–380, 2012. Citado 5 vezes nas páginas 30, 42, 43, 65 e 71.
- RAKSHIT, S.; DEBNATH, S.; MONDAL, D. Identifying land patterns from satellite imagery in amazon rainforest using deep learning. *arXiv preprint arXiv:1809.00340*, 2018. Citado na página 32.

ROCHA, G. F. et al. Detecção de desmatamentos no bioma cerrado entre 2002 e 2009: padrões, tendências e impactos. *Revista Brasileira de Cartografia*, v. 3, n. 63, p. 341–349, 10 2011. Citado 2 vezes nas páginas 23 e 24.

ROSSI, A. L. D. *Ajuste de parâmetros de técnicas de classificação por algoritmos bioinspirados*. Tese (Doutorado) — Universidade de São Paulo, 2009. Citado 3 vezes nas páginas 42, 44 e 46.

SANO, E. E.; JESUS, E. T. de; BEZERRA, H. da S. *Uso de um sistema de informações geográficas para quantificação de áreas remanescentes do cerrado*. [S.l.], 2001. Citado na página 23.

SANTOS, J. A. dos et al. *Semi-Automatic Classification of Remote Sensing Images*. Tese (Doutorado) — Universidade Estadual de Campinas, 2013. Disponível em: <http://www.theses.fr/2013CERG0626/abes>. Citado 10 vezes nas páginas 25, 29, 30, 35, 38, 39, 42, 43, 47 e 65.

SCHIEWE, J. Segmentation of high-resolution remotely sensed data - concepts, applications and problems. *Symposium on Geospatial Theory, Processing and Applications*, p. 1–6, 2002. Citado 2 vezes nas páginas 25 e 36.

SCHULTZ, M. et al. Performance of vegetation indices from landsat time series in deforestation monitoring. *International journal of applied earth observation and geoinformation*, Elsevier, v. 52, p. 318–327, 2016. Citado 3 vezes nas páginas 26, 36 e 40.

SILVEIRA, E. M. et al. Using spatial features to reduce the impact of seasonality for detecting tropical forest changes from landsat time series. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 10, n. 6, p. 808, 2018. Citado na página 40.

SILVEIRA, E. M. d. O. et al. Characterizing landscape spatial heterogeneity using semivariogram parameters derived from ndvi images. *Cerne*, SciELO Brasil, v. 23, n. 4, p. 413–422, 2017. Citado na página 42.

SONG, W.; DENG, X. Land-use/land-cover change and ecosystem service provision in china. *Science of the Total Environment*, Elsevier, v. 576, p. 705–719, 2017. Citado na página 29.

SOUZA-FILHO, P. W. M. et al. Changes in the land cover and land use of the itacaiúnas river watershed, arc of deforestation, carajás, southeastern amazon. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 40, n. 7, p. 1491–1496, 2015. ISSN 16821750. Citado 2 vezes nas páginas 29 e 30.

STEFFEN, C. A.; SOLAR, R. Introdução ao sensoriamento remoto. *INPE. Divisão de Sensoriamento Remoto. Disponível em: < http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm > Acesso em*, v. 6, 2011. Citado 2 vezes nas páginas 35 e 36.

SUN, W.; WANG, R. Fully convolutional networks for semantic segmentation of very high resolution remotely sensed images combined with dsm. *IEEE Geoscience and Remote Sensing Letters*, IEEE, v. 15, n. 3, p. 474–478, 2018. ISSN 1545598X. Citado 3 vezes nas páginas 24, 25 e 37.

TABARELLI, M. et al. Desafios e oportunidades para a conservação da biodiversidade na mata atlântica brasileira. *Megadiversidade*, conservation.org, v. 1, p. 132–138, 7 2005. Citado na página 23.

TARABALKA, Y.; BENEDIKTSSON, J. A.; CHANUSSOT, J. Spectral–spatial classification of hyperspectral imagery based on partitional clustering techniques. *IEEE Transactions on Geoscience and Remote Sensing*, IEEE, v. 47, n. 8, p. 2973–2987, 2009. Citado na página 33.

TOLESSA, T.; SENBETA, F.; KIDANE, M. The impact of land use/land cover change on ecosystem services in the central highlands of ethiopia. *Ecosystem services*, Elsevier, v. 23, p. 47–54, 2017. Citado na página 29.

TRANCOSO, R.; SANO, E. E.; MENESES, P. R. The spectral changes of deforestation in the brazilian tropical savanna. *Environmental monitoring and assessment*, Springer, v. 187, n. 1, p. 4145, 2015. Citado na página 65.

TRIAS-SANZ, R.; BOLDO, D. A high-reliability, high-resolution method for land cover classification into forest and non-forest. In: SPRINGER. *Scandinavian Conference on Image Analysis*. [S.l.], 2005. p. 831–840. Citado na página 29.

TROYA-GALVIS, A.; GANÇARSKI, P.; BERTI-ÉQUILLE, L. A collaborative framework for joint segmentation and classification of remote sensing images. In: *Advances in Knowledge Discovery and Management*. [S.l.]: Springer, 2018. p. 127–145. Citado 2 vezes nas páginas 25 e 33.

TROYA-GALVIS, A.; GANÇARSKI, P.; BERTI-ÉQUILLE, L. Remote sensing image analysis by aggregation of segmentation-classification collaborative agents. *Pattern Recognition*, Elsevier, v. 73, p. 259–274, 2018. Citado na página 39.

WANG, J. et al. Alternative fuzzy cluster segmentation of remote sensing images based on adaptive genetic algorithm. *Chinese Geographical Science*, v. 19, n. 1, p. 83–88, 2009. ISSN 10020063. Citado na página 25.

WANG, Y. et al. Region merging considering within-and between-segment heterogeneity: An improved hybrid remote-sensing image segmentation method. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 10, n. 5, p. 781, 2018. Citado 4 vezes nas páginas 25, 26, 27 e 33.

WILLIS, K. S. Remote sensing change detection for ecological monitoring in united states protected areas. *Biological Conservation*, Elsevier Ltd, v. 182, p. 233–242, 2015. ISSN 00063207. Disponível em: <<http://dx.doi.org/10.1016/j.biocon.2014.12.006>>. Citado na página 35.

WYNIAWSKYJ, N. S. et al. Forest monitoring in guatemala using satellite imagery and deep learning. In: IEEE. *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium*. [S.l.], 2019. p. 6598–6601. Citado na página 32.

XIE, Y.; SHA, Z.; YU, M. Remote sensing imagery in vegetation mapping: a review. *Journal of Plant Ecology*, v. 1, n. 1, p. 9–23, 2008. Disponível em: <<http://dx.doi.org/10.1093/jpe/rtm005>>. Citado 2 vezes nas páginas 35 e 36.

XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, Hindawi, v. 2017, 2017. Citado na página 40.

YANG, J.; HE, Y.; CASPERSEN, J. Region merging using local spectral angle thresholds: A more accurate method for hybrid segmentation of remote sensing images. *Remote sensing of environment*, Elsevier, v. 190, p. 137–148, 2017. Citado 2 vezes nas páginas 26 e 39.

YUAN, J.; WANG, D. L.; LI, R. Remote sensing image segmentation by combining spectral and texture features. *IEEE Transactions on Geoscience and Remote Sensing*, v. 52, n. 1, p. 16–24, 2014. ISSN 01962892. Citado na página 25.

ZAKI, N. A. M. et al. Dominant tree species estimation for tropical forest using pixel-based classification support vector machine (svm) and object-based classification (obia). In: *Charting the Sustainable Future of ASEAN in Science and Technology*. [S.l.]: Springer, 2020. p. 319–333. Citado na página 68.

ZEGEYE, H. Major drivers and consequences of deforestation in ethiopia: Implications for forest conservation. *Asian Journal of Science and Technology*, v. 8, n. 08, p. 5166–5175, 2017. Citado na página 23.

ZEILEIS, A. Implementing a class of structural change tests: An econometric computing approach. *Computational Statistics & Data Analysis*, Elsevier, v. 50, n. 11, p. 2987–3008, 2006. Citado na página 40.

ZHANG, L.; ZHANG, L.; DU, B. Deep learning for remote sensing data: A technical tutorial on the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, v. 4, n. 2, p. 22–40, 2016. ISSN 21686831. Citado na página 44.

ZHANG, X.; XIAO, P.; FENG, X. Object-specific optimization of hierarchical multiscale segmentations for high-spatial resolution remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 159, p. 308–321, 2020. Citado na página 54.

ZHANG, X. et al. Hybrid region merging method for segmentation of high-resolution remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 98, p. 19–28, 2014. Citado na página 33.

ZHU, Z. Change detection using landsat time series: A review of frequencies, preprocessing, algorithms, and applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 130, p. 370–384, 2017. Citado na página 26.

ZOPE, P.; ELDHO, T.; JOTHIPRAKASH, V. Impacts of land use–land cover change and urbanization on flooding: A case study of oshiwara river basin in mumbai, india. *Catena*, Elsevier, v. 145, p. 142–154, 2016. Citado na página 29.

## APÊNDICE A – Processamento de Imagens

De forma geral, os materiais utilizados ao longo do estudo foram: imagens de SR e informações de autuações de fiscalizações ambientais realizadas pela Polícia Militar Ambiental do Estado de São Paulo.

Parte das imagens analisadas foram capturadas pelo satélite CBERS 4, que é dotado de um câmera pancromática com 3 bandas multi-espectrais (bandas 2, 3 e 4) de 10m de resolução espacial e uma pancromática (banda 1) com 5m. Para extrair informações mais acuradas das imagens, foi efetuado o processo de *pansharpening* com o objetivo de obter todas as bandas com a resolução de 5m.

A [Figura 60](#) corresponde a grade de órbitas e pontos que cobrem o estado de São Paulo pelo satélite CBERS 4. A partir dessa identificação é possível definir de modo simples a qual região uma imagem de SR pertence. Desde a primeira imagem proveniente do satélite CBERS 4 com a câmera PAN até a data pesquisada, foram encontradas 1.451 imagens da banda 1 e 1.222 imagens multi-espectrais para a cobertura da [Figura 60](#), isso acontece pois

"essa câmera tem uma faixa de imageamento de 60 km. Essa faixa estreita faz com que a PAN tenha um tempo de revisita no equador prejudicado em relação aos outros imageadores. Como importante consequência está o fato de que o padrão orbital com ciclo de 26 dias não lhe permite cobrir totalmente o equador. Para sanar esse inconveniente, esse imageador é dotado de um espelho de visada lateral, desenvolvido para cobrir faixas adjacentes ao percurso sub-satélite (EPIPHANIO, 2011)".

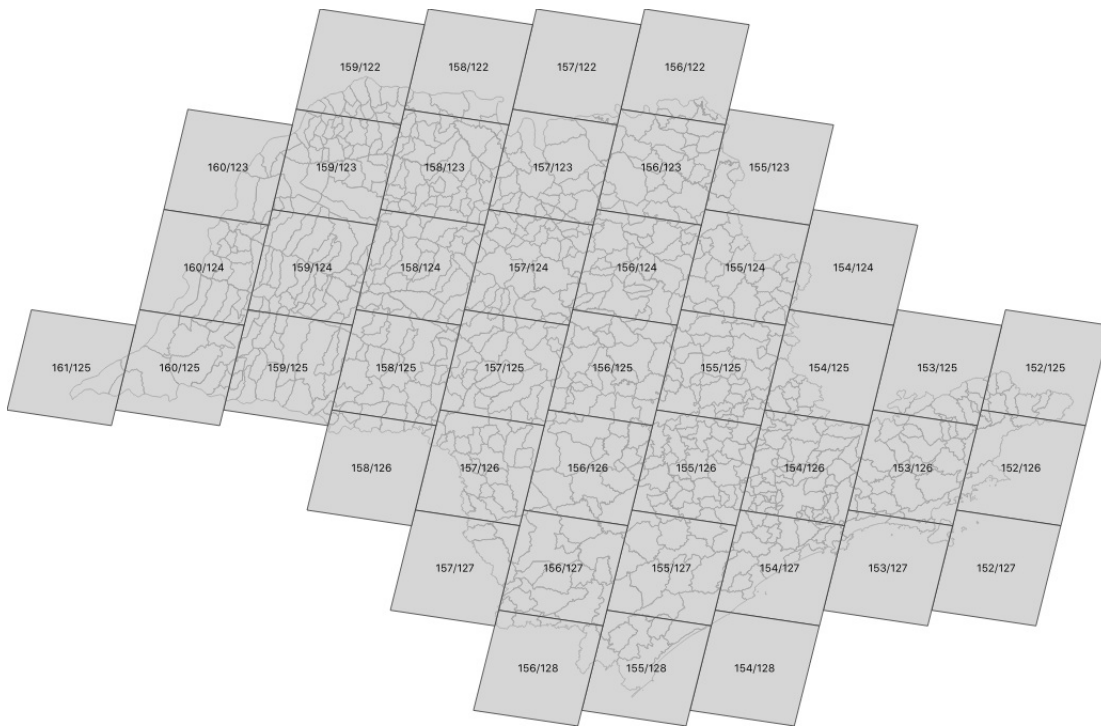
Como consequência, após a remoção das imagens impossibilitadas de alcançar os 5m de resolução e as imagens que estavam 100% na região do oceano Atlântico, restaram 268 imagens.

Essas imagens foram analisadas visualmente para que fossem selecionadas as mais semelhantes com as fiscalizações da polícia. Em outras palavras, devido ao insuficiente número de imagens e a presença de nuvens, algumas regiões não possuíam dados anteriores ou posteriores aos eventos de atuação. Isso explica o número reduzido de fiscalizações validadas.

Após a seleção dos dados foi constatado que as posições das fiscalizações não coincidem com as imagens georreferenciadas em consequência ao fato de que a câmera PAN gera “deslocamentos posicionais significativos das imagens georreferenciadas” (AKIYAMA; JUNIOR; TOMMASELLI, 2019). Para efetuar o georreferenciamento das imagens foi utilizado um *plugin* denominado *Freehand raster georeferencer* acoplado ao software QGis.

A [Figura 61](#) mostra uma autuação realizada no município de Paraíso-SP no ano de

Figura 60: Grade com órbitas e pontos para a cobertura do estado de SP com o satélite CBERS 4.



Fonte: elaborada pelo autor.

2017 projetada sobre uma imagem retirada do *Google Earth* para facilitar a visualização do deslocamento na [Figura 62](#) que contém a mesma fiscalização projetada sobre a imagem do satélite CBERS 4 capturada em 2019.

Figura 61: Autuação da polícia projetada sobre uma imagem do *Google Earth*.



Fonte: elaborada pelo autor.

Figura 62: Autuação da polícia projetada sobre a imagem do satélite CBERS 4.



Fonte: elaborada pelo autor.

Após a correção geográfica realizada na [Figura 62](#), a [Figura 63](#) exibe outra autuação realizada no mesmo município e mesmo ano. Comparando-a com a [Figura 64](#), é possível



constatar deslocamento análogo. Por essa razão o processo de georreferenciamento foi executado para todas as fiscalizações avaliadas.

Figura 63: Autuação da polícia projetada sobre uma imagem do *Google Earth*.



Fonte: elaborada pelo autor.

Figura 64: Autuação da polícia projetada sobre a imagem do satélite CBERS 4.



Fonte: elaborada pelo autor.

Finalmente, com as imagens posicionadas corretamente, foi possível aplicar os métodos de segmentação e analisar os resultados.




## APÊNDICE B – Resultados de segmentação


A seguir estão dispostos os resultados das segmentações em duas regiões degradadas fiscalizadas pela Polícia Militar Ambiental. Todas as imagens foram capturadas com satélite CBERS 4 e portanto, possuem 5m de resolução espacial.

A primeira ação foi realizada no município de Jacupiranga no ano de 2017 e é representada pela [Figura 65](#) e [Figura 66](#) obtidas em 2017 antes e após a degradação, respectivamente.

Figura 65: Imagem original adquirida anteriormente a degradação.      Figura 66: Imagem original adquirida após a degradação.



Fonte: elaborada pelo autor.



Fonte: elaborada pelo autor.

A [Tabela 9](#) auxiliará na análise dos resultados, pois apresenta as métricas de LCE, GCE e Kappa Index para as segmentações da [Figura 65](#) (coluna Floresta) e da [Figura 66](#) (coluna Desmatado).


A [Figura 67](#) e [Figura 68](#) são resultados do método de segmentação multi-escala. Os retângulos vermelhos indicam regiões que deveriam ser segmentadas baseadas na mudança de vegetação e solo exposto presentes. A razão pela qual os valores de LCE e GCE estarem consideravelmente abaixo da média é explicado pelos retângulos brancos, no qual houve um bom delineamento dos segmentos. Além do mais, devido ao *ground truth* analisado possuir poucos segmentos, todas as regiões menores da segmentação que estiverem contidas no *ground truth* terão erro igual a 0. Contudo, a métrica Kappa Index representa os resultados consideráveis relacionados a classificação dos segmentos para as técnicas de AM, SAVI e a abordagem colaborativa.

Tabela 9: Métricas de LCE, GCE e Kappa Index para cada método de segmentação aplicado

Método de Segmentação	Floresta			Desmatado		
	LCE (%)	GCE (%)	Kappa	LCE (%)	GCE (%)	Kappa
Multi-escala	4,54	4,66	0,48	5,41	5,48	0,43
<i>Marker-controlled watershed-based</i>	4,25	7,96	0,47	3,90	6,01	0,51
SAVI	3,79	5,91	0,70	3,06	5,38	0,77
Técnica de AM	5,79	6,29	0,73	4,20	4,61	0,67
Estrutura colaborativa de segmentação	3,64	5,60	0,77	3,05	3,82	0,79


Fonte: Elaborada pelo autor.

Figura 67: Resultado do método multi-escala para a Figura 65.



Fonte: elaborada pelo autor.

Figura 68: Resultado do método multi-escala para a Figura 66.




Fonte: elaborada pelo autor.

Os resultados do método *marker-controlled watershed-based*, indicados pela Figura 69 e Figura 70 demonstram uma sutil instabilidade da segmentação. Na Figura 69, os retângulos brancos indicam as regiões bem delineadas, todavia, o polígono vermelho reflete uma área considerável de desmatamento que não foi segmentada. Contudo, a Figura 70 apresenta uma boa segmentação, fato que pode ser visto na diferença dos resultados na Tabela 9, cujos valores da imagem anterior ao desmatamento (coluna Floresta) foram maiores que os posteriores.

O resultado da técnica de AM cometeu algumas falhas no momento da classificação dos fragmentos, o que resultou no erro durante a classificação (polígonos vermelhos na Figura 71 e Figura 72) e mesmo assim o resultado foi considerável em ambas as imagens. O método também permite a rotulação dos segmentos em presença ou ausência de florestas corroborando para formação da abordagem colaborativa.


O método de segmentação gerado pelo SAVI apresentou instabilidade entre as duas

Figura 69: Resultado do método *marker-controlled watershed-based* para a Figura 65.




Fonte: elaborada pelo autor.

Figura 70: Resultado do método *marker-controlled watershed-based* para a Figura 66.




Fonte: elaborada pelo autor.

Figura 71: Resultado da técnica de AM para a Figura 65.



Fonte: elaborada pelo autor.


Figura 72: Resultado da técnica de AM para a Figura 66.




Fonte: elaborada pelo autor.

imagens. Na [Figura 73](#) o resultado foi inferior e é possível notar áreas (indicadas pelos polígonos vermelhos) nas quais houve uma sub-segmentação, ou seja, foram erroneamente segmentadas, entretanto, a [Figura 74](#) obteve um resultado considerável com erros menores (quadrado vermelho) e relevantes regiões demarcadas corretamente (polígono branco). Uma diferença entre o método aplicado nas duas imagens que pode ter influenciado nos resultados é o parâmetro  $L$  descrito na [Seção 3.3](#).

Figura 73: Resultado do método SAVI para a [Figura 65](#). Figura 74: Resultado do método SAVI para a [Figura 66](#).



Fonte: elaborada pelo autor.



Fonte: elaborada pelo autor.


O resultado da abordagem colaborativa se assemelhou ao do método SAVI. Os erros indicados pelos polígonos vermelhos na [Figura 75](#) e [Figura 76](#) mostram regiões sub-segmentadas. Em contrapartida mesmo com resultados das métricas LCE, GCE e Kappa Index similares, a abordagem alcançou leves melhorias, produto da combinação de todos os métodos de segmentação.

A [Figura 77](#) e a [Figura 78](#) identificam a área da infração demarcada com o uso de GPS pela Polícia Militar Ambiental do Estado de São Paulo e a área sugerida pelo método desenvolvido, respectivamente. Dois fatores podem explicar a diferença entre as imagens: i) a polícia desconsidera áreas degradadas e autorizadas em conformidade com a Lei; ii) as imagens segmentadas pela abordagem colaborativa não foram nas mesmas datas em que a polícia efetuou a fiscalização.

Ainda que existam diferenças, é possível visualizar semelhanças entre as regiões indicando que o método desenvolvido detectou corretamente regiões degradadas.


A segunda autuação analisada foi no município de Lavínia, cuja infração ocorreu no ano de 2018. A [Figura 79](#) e [Figura 80](#) expõem as imagens originais segmentadas antes e depois do desflorestamento, respectivamente.

Figura 75: Resultado da abordagem colaborativa para a Figura 65.




Fonte: elaborada pelo autor.

Figura 76: Resultado da abordagem colaborativa para a Figura 66.




Fonte: elaborada pelo autor.

Figura 77: Autuação delimitada manualmente com o auxílio de GPS pela Polícia Militar Ambiental.




Fonte: elaborada pelo autor.

Figura 78: Sugestão de área degradada identificada pela abordagem colaborativa.




Fonte: elaborada pelo autor.

Figura 79: Imagem original adquirida anteriormente a degradação. Figura 80: Imagem original adquirida após a degradação.



Fonte: elaborada pelo autor.



Fonte: elaborada pelo autor.

Analogamente à Tabela 9, a Tabela 10 apresenta as métricas de LCE, GCE e Kappa Index para as segmentações da Figura 79 (coluna Floresta) e da Figura 80 (coluna Desmatamento).

Tabela 10: Métricas de LCE, GCE e Kappa Index para cada método de segmentação aplicado

Método de Segmentação	Floresta			Desmatado		
	LCE (%)	GCE (%)	Kappa	LCE (%)	GCE (%)	Kappa
Multi-escala	4,54	4,66	0,53	5,41	5,48	0,55
<i>Marker-controlled watershed-based</i>	5,96	9,18	0,65	7,71	12,28	0,53
SAVI	5,03	19,40	0,65	3,27	5,27	0,76
Técnica de AM	11,01	21,68	0,60	6,08	7,93	0,62
Estrutura colaborativa de segmentação	9,42	16,84	0,70	5,20	6,13	0,75


Fonte: Elaborada pelo autor.

Os resultados do método multi-escala (Figura 81 e Figura 82) apresentam análises semelhantes as outras figuras consequentes do mesmo segmentador. Os polígonos azuis indicam regiões em que as bordas foram bem delineadas e as regiões vermelhas evidenciam áreas onde a super-segmentação não foi satisfatória.

Embora na Figura 83 e a Figura 84 os resultados do método *marker-controlled watershed-based* não tenham atingido valores expressivos para as métricas de LCE e GCE, estas possuem uma característica importante para a abordagem colaborativa. Tal particularidade é observada nas cores dessas imagens, como por exemplo na Figura 84, a cor avermelhada foi criada pelo método tanto na região norte, quanto no sul da imagem, onde existem semelhanças entre elas. Assim, o processo de classificação das regiões segmentadas




Figura 81: Resultado do método multi-escala para a Figura 79.



Fonte: elaborada pelo autor.


Figura 82: Resultado do método multi-escala para a Figura 80.



Fonte: elaborada pelo autor.


pele método se torna mais suave, pois a comparação dessas áreas com a técnica de AM e o método SAVI possuem maior quantidade de *pixels*.

Figura 83: Resultado do método *marker-controlled watershed-based* para a Figura 79.



Fonte: elaborada pelo autor.


Figura 84: Resultado do método *marker-controlled watershed-based* para a Figura 80.



Fonte: elaborada pelo autor.


A técnica de AM apresentou um resultado inferior na Figura 85 e na Figura 86. Isso é devido a falta de conhecimento dos modelos em fragmentos mais escuros (polígonos vermelhos). A Figura 85 também possui uma demarcação amarela indicando que a técnica classifica regiões de vegetação possivelmente rasteira, como ausência de florestas. Uma possibilidade para melhorar esse resultado seria a inclusão de novas amostras no processo de treinamento do classificador.

Figura 85: Resultado da técnica de AM para a Figura 79.



Fonte: elaborada pelo autor.

Figura 86: Resultado da técnica de AM para a Figura 80.




Fonte: elaborada pelo autor.

A Figura 87 e a Figura 88 são resultados do método de segmentação SAVI. Por vezes, as bordas geradas pelo segmentador em regiões pequenas são extrapoladas, como os casos indicados em amarelo. O método também possui dificuldades para segmentar áreas cujo índice se manteve próximo ao limite (casos de vegetação rasteira evidenciados na cor vermelha). Todavia, o método é sensível para separar regiões maiores entre vegetação e ausência desta.


Foi constatado segundo os valores de LCE e GCE da Tabela 10 que o método obtém resultados mais acurados em imagens que possuem poucos detalhes, por exemplo a Figura 88.

Figura 87: Resultado do método SAVI para a Figura 79.



Fonte: elaborada pelo autor.


Figura 88: Resultado do método SAVI para a Figura 80.



Fonte: elaborada pelo autor.


Os resultados obtidos pelo método proposto na [Figura 89](#) e na [Figura 90](#) apresentam suas desvantagens, o que resultou na porcentagem de erro elevada. A imagem anterior ao desmatamento mostra uma semelhança com o resultado do método multi-escala. Os polígonos amarelos indicam que, em certos casos, esse resultado é caracterizado pela presença de estradas, entretanto, em outras situações podem ser resultantes de uma supersegmentação. Na [Figura 90](#) são delineados na cor vermelha os segmentos provenientes da técnica de AM que obtiveram um erro elevado. Sendo assim, os resultados da abordagem colaborativa para esse conjunto de imagens obteve um valor inferior.

Figura 89: Resultado da abordagem colaborativa para a [Figura 79](#).



Fonte: elaborada pelo autor.

Figura 90: Resultado da abordagem colaborativa para a [Figura 80](#).




Fonte: elaborada pelo autor.

Igualmente as figuras apresentadas para a cidade de Jacupiranga ([Figura 77](#) e [Figura 78](#)), a [Figura 91](#) e a [Figura 92](#) comparam a área da infração demarcada pela polícia e a área sugerida pelo método desenvolvido, respectivamente.


Novamente são analisadas diferenças entre as imagens, porém isso não caracteriza um erro. Ainda que o resultado do método de segmentação proposto tenha obtido certas desvantagens, a área de desmatamento sugerida corresponde a região correta.

Figura 91: Autuação delimitada manualmente com o auxílio de GPS pela Polícia Militar Ambiental.



Fonte: elaborada pelo autor.

Figura 92: Sugestão de área degradada identificada pela abordagem colaborativa.



Fonte: elaborada pelo autor.