

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM MEIO
AMBIENTE E RECURSOS HÍDRICOS

CARACTERIZAÇÃO E DETECÇÃO DE MUDANÇAS
EM ÁREAS DE PRESERVAÇÃO PERMANENTE COM
USO DE GEOTECNOLOGIAS

Kleber Barcelar Santos

Itajubá, Brasil

2021

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM MEIO
AMBIENTE E RECURSOS HÍDRICOS

KLEBER BARCELAR SANTOS

CARACTERIZAÇÃO E DETECÇÃO DE MUDANÇAS
EM ÁREAS DE PRESERVAÇÃO PERMANENTE COM
USO DE GEOTECNOLOGIAS

Dissertação submetida ao Programa de Pós-graduação em Meio Ambiente e Recursos Hídricos, como parte dos requisitos para obtenção do título de Mestre em Meio Ambiente e Recursos Hídricos.

Área de concentração:

Meio Ambiente e Recursos Hídricos

Orientadora:

Prof^a Dra. Nívea Adriana Dias Pons

Coorientadora:

Prof^a Dra. Samara Calçado de Azevedo

Itajubá, Brasil

2021

AGRADECIMENTOS

Agradeço aos meus pais que me apoiaram e me auxiliaram na minha caminhada. Vocês são anjos na minha vida. É um prazer dividir a minha existência neste plano com seres tão iluminados.

Agradeço aos meus amigos que sempre estiveram ao meu lado e me ajudaram da forma que fosse possível. Vocês são espetaculares!

Agradeço à minha namorada Isadora que me ajudou nos momentos difíceis e de desespero e que fez esse trabalho ser mais leve e gratificante.

Agradeço às minhas orientadoras, Nívea e Samara que me auxiliaram e possibilitaram meu desenvolvimento pessoal e profissional, além de terem paciência comigo.

Agradeço ao 17º Departamento da Polícia Civil de Minas Gerais que disponibilizou os dados utilizados nessa dissertação.

Agradeço à CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo bolsa de estudos.

RESUMO

As Áreas de Preservação Permanente (APP) são uma das ferramentas legais para a conservação da vegetação nativa restante no país, visto que, em todo o processo de ocupação no Brasil, a fauna e flora sofrem pressão das intervenções antrópicas. Nesse contexto, o monitoramento e preservação dessas áreas são essenciais para a manutenção dos biomas brasileiros, principalmente para o bioma Mata Atlântica que vem sofrendo crescentes perdas. Nesse estudo objetiva-se a avaliar o potencial da classificação baseada a objetos na identificação e mapeamento de intervenções antrópicas em APP no Sul de Minas Gerais (MG). Primeiramente realizou-se uma análise exploratória dos dados de ocorrências de intervenções antrópicas em APP no Sul de Minas nos anos de 2011 a 2019 obtidos com a Polícia Civil (PC) de MG. Os resultados dessa análise apontaram para uma tendência de redução no número de ocorrências, com a identificação de maiores aumentos anuais nos números de ocorrências para os municípios de Estiva e Pouso Alegre. A segunda etapa foi o processo de mapeamento das intervenções realizado pela utilização de uma classificação orientada a objetos (GEOBIA) no *software eCognition* em imagens do satélite *Sentinel-2*, com a aplicação de conceitos de *Data Mining* e *Machine Learning*. A área de estudo escolhida foi o município com maior índice de aumento de ocorrências de intervenção em APP no período recente de 2016-2019 e o período escolhido foi o mês com maior incidência de ocorrências. Como resultado foi obtida uma variação negativa de vegetação arbórea em junho de 2018 no município de Pouso Alegre. Dessa variação de vegetação arbórea, 0,74 km² foram de mudanças no uso do solo de APP, distribuídos em 3043 pontos, sendo 138 deles com áreas maiores que 1.000 m². As classificações obtiveram desempenho equilibrado (PRC-*Precision and Recall under the curve* e ROC-*Received Operator Characteristic under the curve* próximos de 1) e satisfatório (Índice Kappa de 0,9072; *F-Measure* médio de 0,926; MMC médio de 0,908), com apenas uma classe (cultivo) com confusão significativa na matriz de erros. Os resultados encontrados foram considerados satisfatórios e, desta forma, espera-se que esse trabalho sirva como auxílio no planejamento e gestão dos recursos da Polícia Civil a fim de que haja uma fiscalização e combate efetivos ao desmatamento do bioma Mata Atlântica no Sul de Minas Gerais.

Palavras-chave: Crimes ambientais; Sensoriamento Remoto; *Machine Learning*; *Data Mining*; Mata Atlântica.

LISTA DE FIGURAS

Figura 1.1 - Localização das três regionais sob comando do 17º Departamento da Polícia Civil de Minas Gerais, Brasil	18
Figura 1.2 - Localização de cada delegacia regional e dos pontos médios calculados das ocorrências de intervenções antrópicas em APP do Sul de Minas Gerais.....	20
Figura 1.3 - Ocorrências anuais de intervenções antrópicas em APP na 1ª Regional.....	22
Figura 1.4 - Distribuição espacial das ocorrências anuais de intervenções antrópicas em APP na 1ª Regional de Pouso Alegre	24
Figura 1.5 - Gráfico de análise de tendência na série temporal da 1ª regional com previsão de 3 anos.....	25
Figura 1.6 - Ocorrências anuais de intervenções antrópicas em APP na 2ª Regional.....	26
Figura 1.7 - Distribuição espacial das ocorrências anuais de intervenções antrópicas em APP na 2ª Regional de São Lourenço.....	28
Figura 1.8 - Gráfico de análise da tendência na série temporal da 2ª regional com previsão de 3 anos.....	29
Figura 1.9 - Ocorrências anuais de intervenções antrópicas em APP na 3ª Regional.....	30
Figura 1.10 - Distribuição espacial das ocorrências anuais de intervenções antrópicas em APP na 3ª Regional de Itajubá	32
Figura 1.11 - Gráfico de análise da tendência na série temporal da 3ª regional com previsão de 3 anos.....	33
Figura 2.1 - Localização da 1ª Regional de Pouso Alegre sob o comando do 17º Departamento da Polícia Civil de Minas Gerais, Brasil	39
Figura 2.2 - Fluxograma da metodologia aplicada.....	40
Figura 2.3 – Mapa de localização das ocorrências do mês de junho no município PA	41
Figura 2.4 – Proximidades das ocorrências do mês de junho em PA.....	42
Figura 2.5 – Esquema de uma árvore de decisão. Medeiros et al. (2014).....	45
Figura 2.6 – Segmentação do mês de junho com exemplo de amostras: a) veg. arbórea; b) veg. rasteira; c) cultivo; d) Solo exposto; e) área construída.	48
Figura 2.7 - Segmentação do mês de julho.....	48
Figura 2.8 – Mapa da classificação temática para a imagem Sentinel-2 de junho/2018.....	50
Figura 2.9 - Mapa da classificação temática para a imagem Sentinel-2 de julho/2018	51

Figura 2.10 – Análise dos dados de mudança de uso do solo. Classe 1 = Veg. arbórea -> veg. rasteira; Classe 2 = Veg. arbórea -> cultivo; Classe 3 = Veg. arbórea -> solo exposto; Classe 4 = Veg. arbórea -> área construída.	53
Figura 2.11 – Gráfico dos testes simultâneos de Games-Howell para a diferença de médias de áreas.	54
Figura 2.12 – Perfil das áreas de variação no uso do solo no município de Pouso Alegre em junho/2018. Classe 1 = Veg. arbórea -> veg. rasteira; Classe 3 = Veg. arbórea -> solo exposto; Classe 4 = Veg. arbórea -> área construída.	56
Figura 2.13 – Mapa de localização das áreas com mudança de uso no solo em APP de calha de rio no município de PA.....	57
Figura 2.14 - Perfil das áreas de variação no uso do solo em APP no município de Pouso Alegre em junho/2018. Classe 1 = Veg. arbórea -> veg. rasteira; Classe 3 = Veg. arbórea -> solo exposto; Classe 4 = Veg. arbórea -> área construída.....	58
Figura 2.15 – Zoom nas proximidades da ocorrência de 25/06/18 em PA	59
Figura 2.16 - Zoom nas proximidades da ocorrência de 28/06/18 em PA	60
Figura 2.17 - Zoom nas proximidades da ocorrência de 29/06/18 em PA	60
Figura 2.18 - Zoom nas proximidades da segunda ocorrência de 29/06/18 em PA.....	61

LISTA DE TABELAS

Tabela 2.1 - Atributos das imagens do mês de junho e julho utilizados na mineração de dados	43
Tabela 2.2 – Dados da exatidão global e índice Kappa da árvore de decisão	49
Tabela 2.3 – Matriz de Confusão para as imagens Sentinel-2 de Pouso Alegre	51
Tabela 2.4 – Índices de acurácia por classe para as imagens Sentinel-2 de Pouso Alegre	52
Tabela 2.5 – Transformações totais e em porcentagem por classe entre as imagens classificadas	52
Tabela 2.10- Informações de Agrupamento Usando o Método de Tukey e 95% de Confiança.	54
Tabela 2.11 – Variações no uso do solo após análise estatística.....	55

LISTA DE ABREVIATURAS E SIGLAS

APP – Área de Preservação Permanente

DAM – Desvio Absoluto Médio

DPM – Desvio Percentual Médio

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária

EPAM – Erro Percentual Absoluto Médio

FN *Rate* – Falsos positivos

GEOBIA – *Geographic Object-Based Image Analysis*

GLDV – *Gray Level Difference Vector*

GLCM – *Gray Level Co-occurrence Matrix*

IBGE – Instituto Brasileiro de Geografia e Estatística

IDH – Índice de Desenvolvimento Humano

IEF – Instituto Estadual de Florestas

MCC – *Mattews Correlation Coefficient*

MG – Estado de Minas Gerais

MOLUSCE – *Modules for Land Use Change Evaluation*

MOLUSCE – *Modules for Land Use Change Evaluation*)

PC – Polícia Civil

PRC *Area* – *Precision and Recall under the curve*

QGIS – *Quantum GIS*

REDS – Relatório de Evento de Defesa Social

ROC *Area* – *Received Operator Characteristic under the curve*

SIG – Sistema de Informações Geográficas

SISEMA – Sistema Estadual de Meio Ambiente e Recursos Hídricos

SQL – *Structured Query Language*

SR – Sensoriamento Remoto

TP *Rate* – Positivos verdadeiros

UC – Unidade de Conservação

SUMÁRIO

INTRODUÇÃO GERAL	11
OBJETIVOS	14
OBJETIVO GERAL	14
OBJETIVOS ESPECÍFICOS	14
CAPÍTULO I	15
1.1. INTRODUÇÃO	16
1.2. MATERIAIS E MÉTODOS	17
1.2.1. Área de estudo	17
1.2.2. Metodologia.....	18
1.3. RESULTADOS E DISCUSSÃO	20
1.4. CONCLUSÕES	33
REFERÊNCIAS BIBLIOGRÁFICAS	34
CAPÍTULO II.....	36
2.1. INTRODUÇÃO	37
2.2. MATERIAIS E MÉTODOS.....	39
2.2.1. Área de estudo	39
2.2.2. Metodologia.....	39
2.3. RESULTADOS E DISCUSSÃO.....	47
2.3.1. Segmentação.....	47
2.3.2. Mineração de dados	49
2.3.3. Árvores de decisão.....	49
2.3.4. Mapas temáticos	49
2.3.5. Análise de mudanças no uso do solo.....	52
2.4. CONCLUSÕES	61
REFERÊNCIAS BIBLIOGRÁFICAS	63

CONSIDERAÇÕES FINAIS	66
REFERÊNCIAS BIBLIOGRÁFICAS GERAIS.....	67
APÊNDICE I – Testes de tendência 1ª regional.....	70
APÊNDICE II – Testes de tendência 2ª regional	72
APÊNDICE III – Testes de tendência 3ª regional.....	74
APÊNDICE IV – <i>Script</i> de formatação dos dados para inserção no <i>software</i> WEKA.....	76
APÊNDICE V – Árvore de decisão	77
APÊNDICE VI – <i>Scripts</i> de exportação da classificação	86
APÊNDICE VII – Fluxograma da árvore de decisão.....	87
APÊNDICE VIII – Teste estatístico ANOVA com comparação emparelhada de Tukey e comparações múltiplas Dunnett.....	88

INTRODUÇÃO GERAL

O processo de ocupação do Brasil constituiu-se historicamente pela substituição da paisagem nativa por atividades antrópicas, principalmente pelo urbanismo e atividades agropecuárias, por meio da exploração excessiva dos recursos naturais, sem a consideração da sustentabilidade (COUTINHO *et al.*, 2013). Esse processo de ocupação trouxe uma grande pressão ao meio ambiente (CHAICHI; DAIM, 2018). As interferências humanas nas paisagens nativas converteram extensas e contínuas áreas de cobertura vegetal em fragmentos de florestas, comprometendo suas funções ambientais e, conseqüentemente, as contribuições destas para os ecossistemas (TREVISAN *et al.*, 2020). Essa supressão agrava o processo de degradação ambiental, ocasionando impactos negativos para a fauna e flora (SILVA *et al.*, 2015).

Um dos recursos legais que visa reduzir o impacto das atividades antrópicas e preservar os fragmentos restantes, além de mitigar os danos causados, são as Áreas de Preservação Permanente (APP) (GASS *et al.*, 2016). Definidas pela Lei 12.651/2012, o Novo Código Florestal Brasileiro de 2012, as APP são áreas cobertas ou não por vegetação nativa, que possui a função de proteger os recursos naturais, recursos hídricos, a paisagem, a estabilidade geológica, a fauna e flora e também de assegurar o bem-estar da sociedade (BRASIL, 2012). Além da função ambiental de preservar a vegetação e a biodiversidade, as APP possuem uma importância social e econômica, uma vez que as áreas conservadas também têm valor social e econômico (MMA, 2011).

Visto que a função de preservar o meio ambiente é de responsabilidade do estado, este, por sua vez, utiliza da política ambiental para controlar e fiscalizar a devastação ambiental (TRIDAPALLI *et al.*, 2011). Nessa perspectiva, o Estado de Minas Gerais aprovou a Lei nº 20.992 de 16 de dezembro de 2013, que corresponde à política florestal e de proteção da biodiversidade do Estado (MINAS GERAIS, 2013). Todavia, mesmo após o Novo Código Florestal e dos esforços dos Estados em combater a degradação, o cenário de uso conflitivo de solo em áreas de preservação ainda pode ser encontrado em boa parte dos principais biomas (INPE, 2019). De acordo com o último relatório do SOS Mata Atlântica (2019), MG tem demonstrado um incremento nas taxas de desmatamento.

O Sul de Minas Gerais (MG) é caracterizado, em sua grande maioria, por pequenas propriedades, sendo considerado o segundo estado com maior número de propriedades rurais, de acordo com o IBGE (2017), e possui o setor agropecuário como grande segmento econômico

da região. As principais atividades da região são a cafeicultura, olericultura, plantação de milho e atividades de pecuária leiteira (CASTRO, 2016). Além disso, em muitas propriedades rurais, principalmente as de pequeno porte, as APP são ocupadas com atividades agrícolas e pecuária, dado que não há uma grande disponibilidade de área e essas atividades são representativas na renda dos proprietários (MARTINS; REZENDE, 2020).

Nessa acepção, o monitoramento de intervenções antrópicas em APP se faz necessário e as geotecnologias assumem um importante papel. Técnicas de Sensoriamento Remoto e Geoprocessamento têm sido amplamente usadas para estudos ambientais em diversas áreas (SILVA; GUIMARÃES; OLIVEIRA, 2017). Os Sistemas de Informações Geográficas (SIG) facilitam as análises, as simulações do espaço geográfico e seus processos naturais e a interação desses com a informação espacial, visando a produção de mapas com predições de degradação e urbanização (O’SULLIVAN; BERGMANN; THATCHER, 2018; PONDORFER, 2019). As aplicações de imagens de satélite na análise do uso e ocupação do solo são utilizadas na detecção da degradação vegetal, com a possibilidade de estimar o nível e a evolução ao longo do tempo das degradações (TEIXEIRA; CAMARGO; MARTINS JUNIOR, 2018). Uma dessas aplicações é a classificação supervisionada, que possui diversas metodologias de elaboração, como a classificação *pixel-a-pixel* e a orientada a objetos (GEOBIA), e possibilita a obtenção e análise de diversos dados ambientais de forma indireta de uma vasta área (MOSKAL; DUNBAR; JAKUBAUSKAS, 2002).

Por anos a metodologia de classificação *pixel-a-pixel* foi utilizada amplamente para a geração de mapas temáticos de imagens de satélites, seja pela classificação supervisionada ou não supervisionada (AMARSAIKHAN *et al.*, 2010; AMARSAIKHAN, *et al.*, 2012; ENDERLE; WEITH, 2005). O método *pixel-a-pixel* analisa apenas as propriedades espectrais de cada pixel sem considerar as outras características. Com os avanços tecnológicos e a disponibilidade de dados mais detalhados, a possibilidade de uso das informações espaciais para resultados mais precisos tornou-se realidade (MAKINDE *et al.*, 2016). As classificações baseadas em objetos, do termo *Geographic Object-based Image Analysis* (GEOBIA), foram desenvolvidas com o intuito de aprimorar a técnica *pixel-a-pixel*. Diferentemente da antiga técnica, a classificação pela GEOBIA se baseia em um conjunto de *pixels* similares, que constitui um objeto. Esses *pixels* são agrupados de acordo com as propriedades espectrais, tamanho, forma e textura. A GEOBIA utiliza um processo de segmentação da imagem aliado a algoritmos inteligentes interativo, *Data Mining* e *Machine Learning* para alcançar uma

classificação semiautomática que traz resultados mais acurados que a classificação *pixel-a-pixel* (NYAMJARGAL, 2019; LIU; XIA, 2010; WEIGH; RIGGAN, 2012).

Por esse prisma, esta dissertação objetiva-se em identificar e mapear as intervenções antrópicas em APP no Sul de Minas Gerais.

A dissertação está dividida em dois capítulos: o Capítulo I realizou a análise exploratória do banco de dados, obtido da Polícia Civil do estado de Minas Gerais, de ocorrências de intervenções antrópicas em APP no Sul de Minas Gerais, no período de 2011-2019; e o Capítulo II teve como propósito a utilização da classificação orientada a objetos (GEOBIA) e de conceitos de *Data Mining* e *Machine Learning* para a investigação de intervenções antrópicas em APP no Sul de Minas.

OBJETIVOS

OBJETIVO GERAL

Avaliar o potencial da classificação baseada em objetos na identificação e mapeamento de intervenções antrópicas em Áreas de Preservação Permanente (APP) no Sul de Minas Gerais.

OBJETIVOS ESPECÍFICOS

Descrever a caracterização espacial e temporal das ocorrências de intervenções antrópicas em APP no Sul de Minas Gerais por meio dos dados obtidos da Polícia Civil.

Identificar os objetos-alvos de mudanças no uso do solo que preconizam as intervenções antrópicas em APP.

Relatar as mudanças de vegetação em APP e suas proximidades.

Inferir a qualidade dos resultados.

CAPÍTULO I

ANÁLISE MULTITEMPORAL DA DISTRIBUIÇÃO DE INTERVENÇÕES ANTRÓPICAS EM APP NO SUL DE MINAS GERAIS

RESUMO

A análise de impactos ambientais é uma tarefa fundamental no desenvolvimento da sociedade, uma vez que a preservação ambiental é crucial no planejamento urbano, evitando o uso e ocupação desordenado do solo que acarreta diversos problemas ambientais nos municípios. A principal estratégia de preservação dos ecossistemas remanescentes é a adoção de áreas protegidas, como as Áreas de Proteção Permanente (APP). O objetivo desse estudo é descrever uma análise exploratória, estatisticamente e multitemporalmente, das intervenções antrópicas em APP no Sul de Minas Gerais e identificar os focos dessas violações ambientais por meio do geoprocessamento e dos Sistemas de Informações Geográficas (SIG). As análises foram baseadas nos dados obtidos dos registros de campo dos policiais do 17º Departamento da Polícia Civil de Minas Gerais. Os dados espaciais foram processados no QGIS pelo uso de banco de dados SQL. Um total de 2.806 intervenções antrópicas em APP foram reportadas entre jan. 2011 e dez. 2019 nas três regionais que abrangem o 17º Departamento. A análise multitemporal indicou uma redução das intervenções em 2012 com relação ao ano de 2011 na área estudada. Uma possível explicação seria a revisão das leis ambientais que ocorreu com o Novo Código Florestal adotado no período, trazendo afrouxamentos na legislação ambiental referente à delimitação e preservação das APP. Houve uma tendência de redução dos casos na 1ª e 3ª regionais; a 2ª regional apresentou, a partir de 2017, uma tendência de aumento de ocorrências. O menor índice de intervenção ocorreu na 3ª regional de Itajubá que atingiu uma redução de 66% dos casos no ano de 2018 em comparação com 2011. Por município, as maiores variações positivas no número de ocorrências ocorreram nos municípios de Estiva e de Pouso Alegre, ambos localizados na 1ª Regional. A análise espacial apontou uma alta ocorrência de intervenções próximas às áreas urbanas e análise estatística das séries temporal indicou uma tendência de redução de ocorrências nas três regionais.

Palavras-chave: Análise espacial; Áreas de Proteção Permanente; SIG; QGIS; Estatística.

1.1. INTRODUÇÃO

O Art. 255 da Constituição Brasileira assegura os direitos da sociedade à um meio ambiente balanceado, onde tanto o governo quanto os cidadãos são responsáveis, sem nenhuma exceção, pela proteção e manutenção do meio ambiente para a presente e futura geração (BRASIL, 1988a). Embora a Legislação Ambiental tenha sofrido diversas alterações ao longo de sua história, a principal estratégia do governo brasileiro para proteção e conservação dos ecossistemas é a adoção de áreas de proteção, como as Áreas de Proteção permanente (APP) e as Unidades de Conservação (UC) (ALTMANN; STANTON, 2018).

A proteção das APP é garantida pelo Código Florestal Brasileiro (12.651/12), conhecido como o novo Código Florestal, o qual substituiu o Código Florestal de 1965, trazendo novos mecanismos e atualizando os já existentes (CAMPAGNOLO *et al.*, 2017). A função das APP é a conservação de recursos naturais como os corpos d'água, vegetação nativa, vegetação no entorno de nascentes e de calha do rio, além de garantir a restauração de áreas degradadas pelas atividades antrópicas (FREITAS; MORAES; STORINO, 2013).

A violação de APP é considerada um crime ambiental de acordo com a Lei de Crimes Ambientais (nº 9.605/98), o qual está relacionado ao crime de poluição do meio ambiente de qualquer forma, incluindo crime contra a fauna e flora, poluição contra ao planejamento urbano e gestão ambiental (BRASIL, 1988b). Além do mais, a manutenção da preservação ambiental é essencial para orientar a organização do uso e ocupação do solo da sociedade, o qual, se não for bem planejado, pode acarretar numerosos problemas ambientais, tais como aumento do escoamento superficial e inundações, surtos epidêmicos, deslizamentos de terra, entre outros (EDELMAN; SCHUSTER; SAID, 2017).

Não obstante dos benefícios oriundos da conservação das APP para a prosperidade da sociedade, pontos controversos na aprovação do novo Código Florestal são apontados. Um deles é a mudança nos limites de APP de calha de rio, visto que houve uma redução no tamanho das faixas a serem preservadas (TANIWAKI *et al.*, 2018; SOARES-FILHO *et al.*, 2014). No sul de Minas Gerais, os efeitos dessa mudança impactarão os recursos naturais da região em breve com o aumento das taxas de desmatamento (STAN *et al.*, 2015).

A Polícia Civil é constitucionalmente responsável pelas funções de polícia judicial e de investigações sobre crimes de ofensa, incluindo as violações das leis ambientais que ocorram na sua jurisdição. O registro de qualquer tipo de crime é feito por um sistema automatizado que

armazena essas informações, todavia o potencial geoespacial desse banco de dados não é devidamente explorado. Estatísticas criminais são fundamentais nas atividades e no planejamento da Polícia Civil (RIBEIRO, 2017). Ademais, Sistemas de Informações Geográficas (SIG) e técnicas de geoprocessamento são ferramentas essenciais na análise de uma gama de problemas ambientais e na provisão de informações para tomadas de decisão (SAURET, 2012). Posto que as intervenções antrópicas no meio ambiente causam distúrbio na conservação dos ecossistemas e que o estado de Minas Gerais (MG) possui uma ampla quantidade de áreas a serem preservadas, MG tende a ter maiores taxas de intervenções antrópicas nessas áreas. A disponibilidade desses dados de intervenções antrópicas em coordenadas geográficas combinada a tecnologia SIG viabiliza uma numerosa quantidade de análises a serem usadas para avaliar as violações de leis ambientais.

O objetivo desse estudo é descrever uma análise exploratória, de forma estatística e multitemporal, das violações de leis ambientais relacionadas às intervenções antrópicas em APP e identificar espacialmente áreas de *hotspots* por meio do uso de técnicas de geoprocessamento e SIG. Dessa forma, esses mapas deverão servir como suporte à tomada de decisão da Polícia Civil, de modo a reduzir gastos excessivos e expandir iniciativas de amparo ao meio ambiente.

1.2. MATERIAIS E MÉTODOS

1.2.1. Área de estudo

O estado brasileiro de Minas Gerais (MG) possui uma vasta área devastadas do bioma Mata Atlântica. De acordo com o boletim de 2019 da Fundação SOS Mata Atlântica, MG apresenta o maior índice de desmatamento de Mata Atlântica entre 2017 e 2018 dentre todos os outros estados. Nos últimos 5 anos, MG esteve entre os 3 mais estados que desmataram (SOS MATA ATLÂNTICA, 2019).

As intervenções em APP avaliadas foram obtidas nos registros do 17º Departamento da Polícia Civil de MG, localizado no sul de Minas Gerais, Brasil. A Figura 1.1 retrata a localização espacial dos 72 municípios sob o comando do 17º Departamento, que consiste em 3 delegacias regionais no Sul de MG. A primeira regional localiza-se no município de Pouso Alegre, disposto na parte sudoeste da região estudada e a maior área das 3 regionais, e abrange 33 municípios a serem monitorados pelos policiais. A segunda regional está localizada na cidade de São Lourenço e engloba 24 municípios. A última regional encontra-se em Itajubá e

abarcas apenas 24 municípios, sendo a menor dentre as regionais do estado. Os três municípios que possuem delegacias regionais possuem juntos uma população estimada de 293.457 habitantes, cerca de 900 km² e um Índice de Desenvolvimento Humano (IDH) médio de 0,773 (IBGE, 2017).

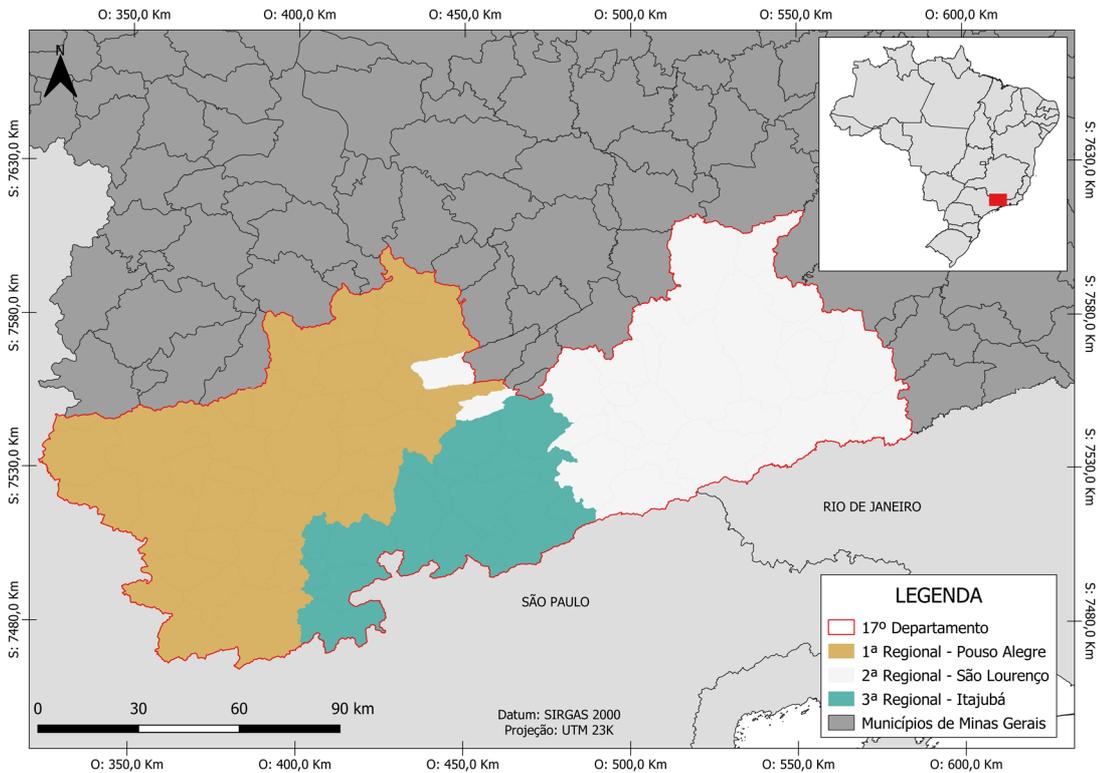


Figura 1.1 - Localização das três regionais sob comando do 17º Departamento da Polícia Civil de Minas Gerais, Brasil

1.2.2. Metodologia

A análise espaço-temporal dos padrões de intervenções antrópicas foi baseada nos registros de campo de policiais civis do 17º Departamento de MG. Esses dados são registrados em um módulo digital chamado REDS (Relatório de Evento de Defesa Social) que possui uma sequência numérica anual única para facilitar o rastreamento da ocorrência. Esse registro é executado, geralmente, no local da denúncia recebida e confeccionado pelo perito da Polícia Civil. O REDS permite a inserção de informações sociais e ambientais, além de computar informações de nome, data, horário, endereço e as coordenadas geográficas da ocorrência, a qual foi utilizada na análise desse estudo.

Do banco de dados da Polícia Civil, foram disponibilizados os registros de ocorrências de intervenções antrópicas em APP de MG no período de 2011 a 2019. Um total de 41.723 ocorrências foram disponibilizadas no formato de arquivo de Excel com uma coluna específica para as coordenadas geográficas de cada ocorrência. Os dados foram processados no *software*

SIG de código aberto Quantum GIS (QGIS), incluindo o *plugin* de banco de dados Spatialite para a aplicação de consultas com a linguagem *Structure Query Language* (SQL) (QGIS, 2019; SPATIALITE, 2015).

A primeira etapa foi selecionar somente as ocorrências no 17º Departamento e suas respectivas regionais por meio de consultas SQL. Após a espacialização dos registros no QGIS, os dados que não pertenciam ao 17º Departamento foram descartados devido a erros de geolocalização no registro do REDS. Na 1ª Regional, 79 registros foram desconsiderados de 1.527 ocorrências, cerca de 5% de dados sem coordenadas corretas. O total de ocorrências foi de 737 na 2ª Regional com 29 registros errôneos de intervenções (cerca de 4%). A regional de Itajubá registrou 677 ocorrências no período avaliado, com 27 casos (cerca de 4%) obtidos com coordenadas equivocadas.

Posterior ao refinamento espacial dos dados, combinações temporais foram executadas no banco de dados com o uso de consultas SQL para organizar e confeccionar os dados em séries anuais para cada regional. Os dados foram analisados no software *RStudio*, por meio da linguagem de programação R, a fim de identificar padrões de variação. Além disso, utilizou-se o *software* Minitab versão 19.2020.01 para realizar uma análise estatística da tendência das séries temporais de ocorrências nas 3 regionais. Testou-se 3 tipos de modelos (quadrático, curva S e linear) e o mais preciso, de acordo com os índices Erro Percentual Absoluto Médio (EPAM) que expressa em porcentagem o erro da previsão; Desvio Absoluto Médio (DAM) e Desvio Percentual Médio (DPM), foi o escolhido para fazer a previsão de ocorrências para 3 anos. Valores menores indicam um ajuste melhor. Geralmente, os três índices são indicados para escolher a melhor previsão, porém o EPAM é o índice mais decisivo em caso de um modelo não ter os menores valores para os três índices (MINITAB, 2019).

Por intermédio da ferramenta de mapas de calor disponível do QGIS, tornou-se mais acessível a identificação e avaliação das áreas mais afetadas por intervenções antrópicas na região sob supervisão do 17º Departamento. Os mapas foram confeccionados com raio de 5km para cada ocorrência. Os seguintes dados de áreas de interesse foram inseridos nos mapas de calor: manchas urbanas, obtidas na Embrapa (2015); rodovias estaduais, retiradas da base de dados do IBGE (2014); hidrografia do banco de dados do SISEMA (2019); e vegetação nativa, dos dados do Instituto Estadual de Florestas (IEF) disponibilizados no SISEMA (2019).

Ademais, por meio da ferramenta “ponto médio” do QGIS, foram analisados os pontos médios das ocorrências de cada regional e o resultado foi comparado à real localização das

delegacias regionais, com o objetivo de avaliar se as centrais regionais estariam posicionadas a fim de gerenciar efetivamente todas as suas respectivas ocorrências ambientais.

1.3. RESULTADOS E DISCUSSÃO

A distribuição espacial das intervenções antrópicas coletadas no banco de dados da Polícia Civil foi realizada conforme a localização geográfica das três regionais descritas na Seção 1.2.1. O ponto médio calculado da distribuição das ocorrências analisadas foi comparado a cada localidade das delegacias regionais, ambas representadas pelos símbolos coloridos e suas respectivas legendas (Figura 1.2). Dentre todas as regionais analisadas, a delegacia regional de Itajubá foi a melhor localizada geograficamente, seguida pela regional de São Lourenço e, por fim, pela a regional de Pouso Alegre. Cabe destacar que a 1ª Regional de Pouso Alegre possui uma maior concentração de intervenções antrópicas em APP distantes da localização da delegacia regional, devido à ampla área que consiste na 1ª Regional, como pode ser notado na Figura 1.2.

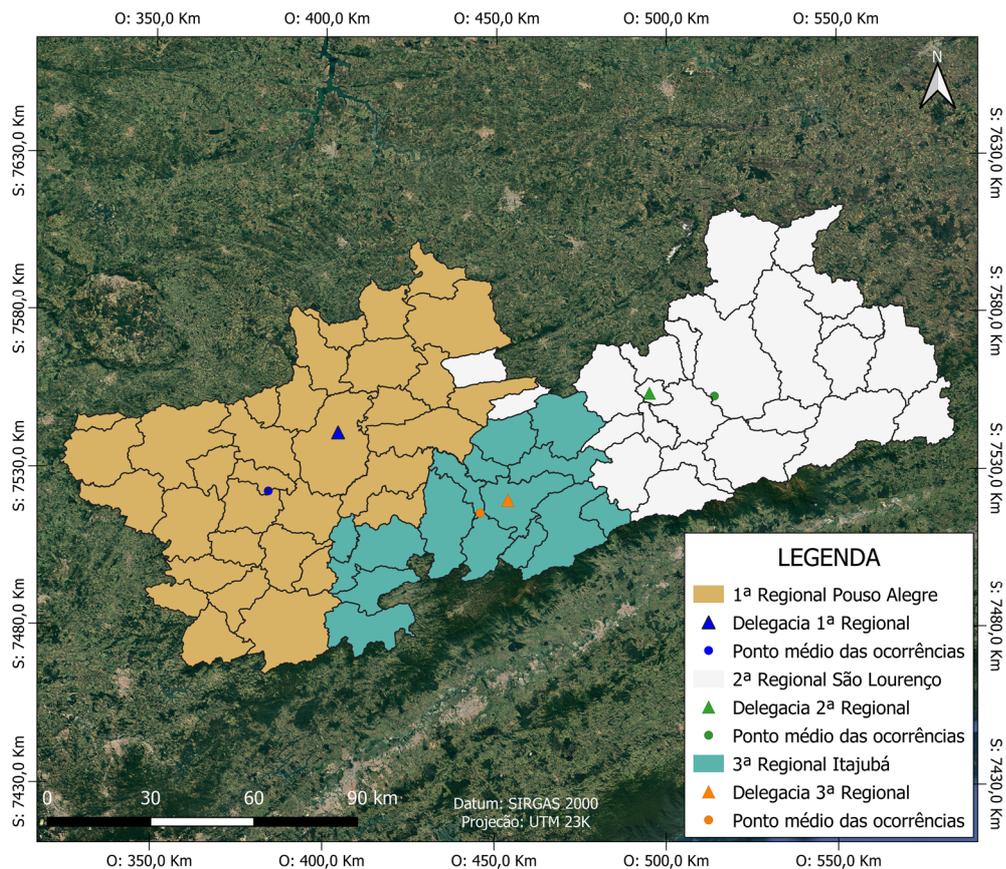


Figura 1.2 - Localização de cada delegacia regional e dos pontos médios calculados das ocorrências de intervenções antrópicas em APP do Sul de Minas Gerais

A Figura 1.3 apresenta a comparação entre o número de ocorrências de intervenções antrópicas por ano (total de 1448 casos) para a 1ª Regional de Pouso Alegre e, na Figura 1.4,

aponta o comportamento espacial dessas ocorrências ao longo do período analisado. Nota-se que na Figura 1.3 houve um decréscimo de 39 (17,1%) no número de ocorrências no ano de 2012, e de 59 (25,9%) no ano de 2013 quando comparados ao ano de 2011. Embora houve uma redução no número de ocorrências observadas, uma maior concentração de intervenções antrópicas foi registrada em um raio de até 80 km da delegacia regional de Pouso Alegre (Figura 1.4). No período 2011-2013 observa-se um padrão concentrado em alguns centros urbanos, como Ouro Fino, Pouso Alegre e Cambuí, fato que não se nota nos anos seguintes, com exceção de 2018 em que se observa uma grande concentração em Pouso Alegre. As ocorrências não demonstram um padrão de proximidade com relação aos dados de rodovias, hidrografia e vegetação nativa. Notou-se, de um modo geral, que as ocorrências tendem a se localizar nas proximidades das áreas urbanas.

Ao Sul de Pouso Alegre, mais especificamente no município de Estiva a menos de 35 km da delegacia regional, o mesmo reportou uma variação positiva de 17 ocorrências de 2012 para 2013. A segunda maior variação nesse período foi no município de Jacutinga, com um incremento positivo de 8 ocorrências.

Por outro lado, houve uma estabilização no número de ocorrências que se iniciou em 2013 e permaneceu até 2016, o qual não superou o limite de variação de 10 ocorrências anuais na 1ª Regional. Cerca de 165 ocorrências foram observadas em 2014 com uma redução de 27,63% em comparação a 2011, ano o qual obteve-se o maior índice de ocorrências de intervenções antrópicas em APP. Destaca-se Pouso Alegre, que de 2015 para 2016, apresentou uma redução de 46, 4% (13 ocorrências). Essa redução observada pode estar relacionada à implementação de melhorias no sistema de controle e digitalização dos dados que aprimoraram as estratégias e esforços da Polícia Civil. Complementarmente, as novas leis ambientais adotadas no Novo Código Florestal em 2012 podem ter otimizado a estratégia, não necessariamente para melhor, de proteção ao meio ambiente e reduzido o número de ocorrências reportadas devido às leis mais brandas.

Uma atenuação nos casos também foi notada em 2017 seguida de um incremento em 2018, todavia mantendo-se 22% abaixo dos anos anteriores. Nesse incremento geral para a 1ª Regional, Pouso Alegre obteve o maior aumento do período 2011-2019 para o município. No ano de 2019 também foi reportada uma redução nas ocorrências, atingindo o menor patamar em todos os anos avaliados. Destaque para Pouso Alegre que obteve a maior redução (8 ocorrências) para o período 2018-2019.

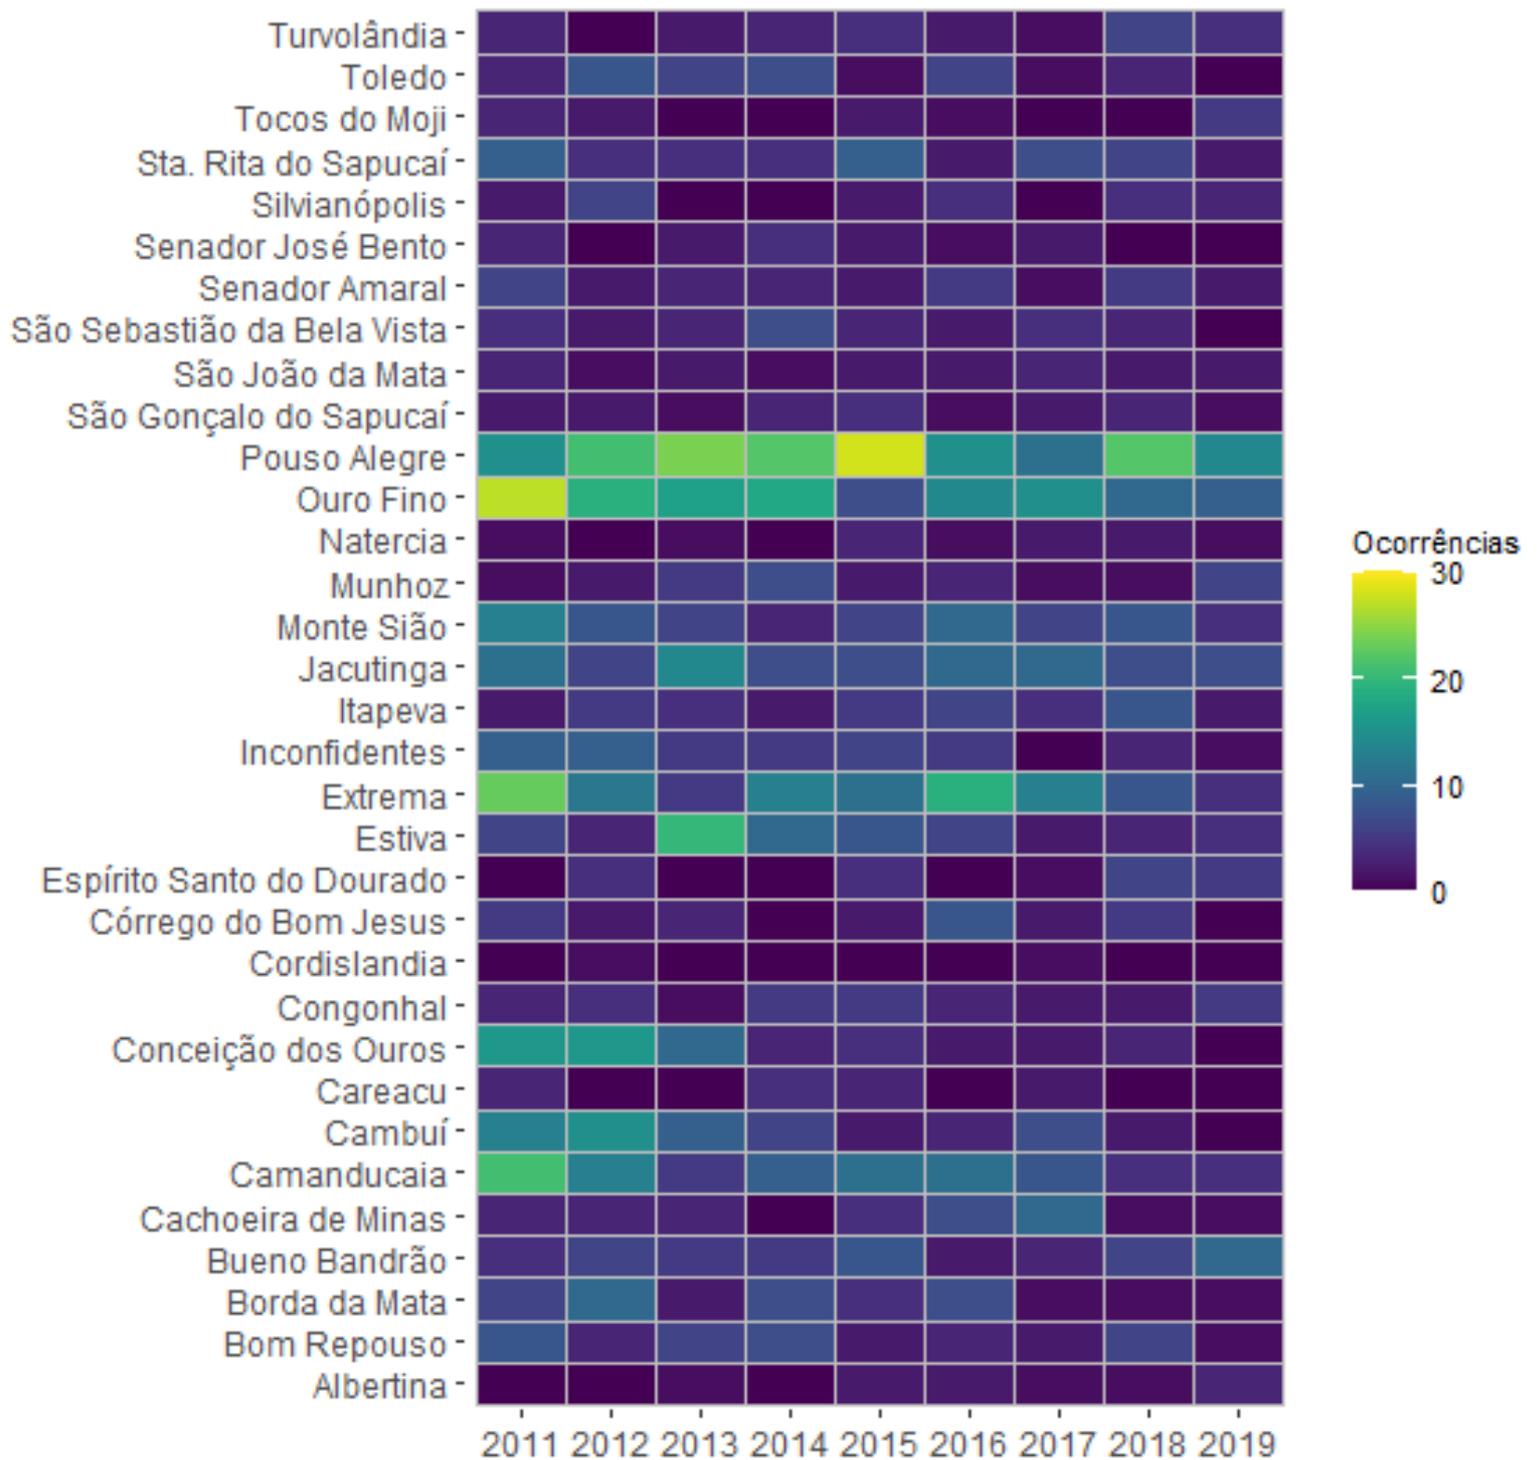
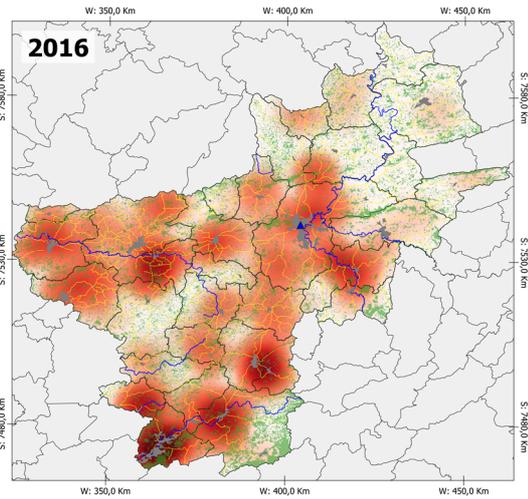
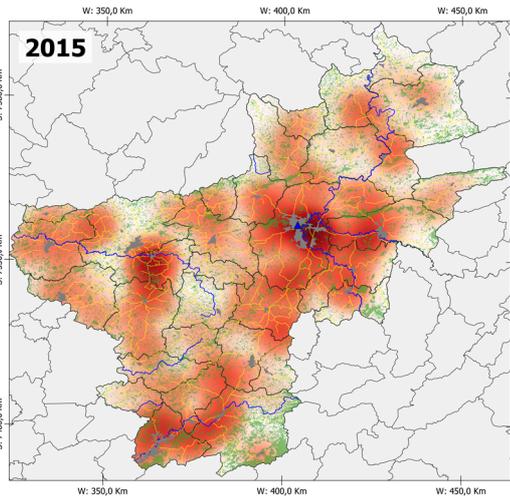
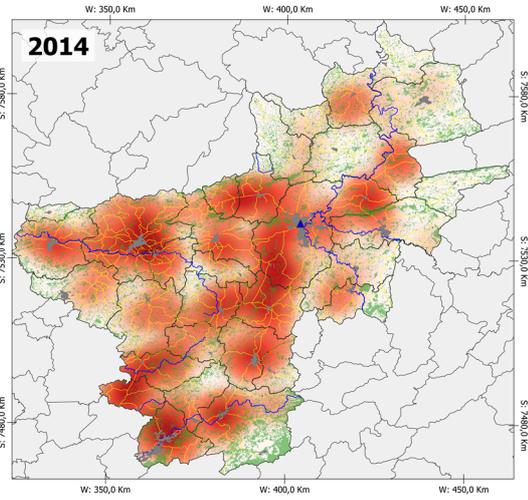
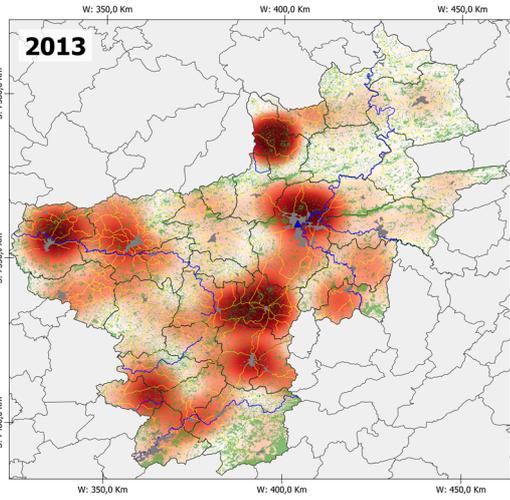
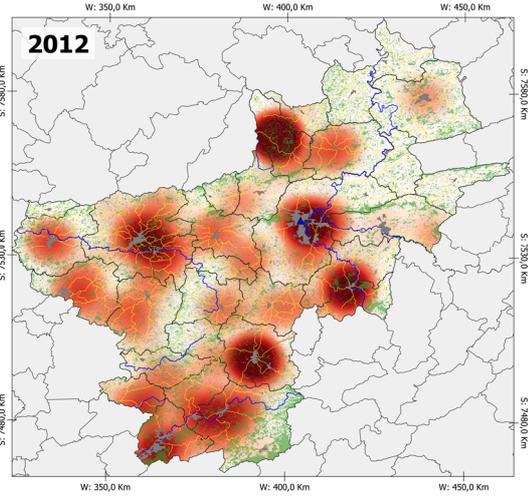
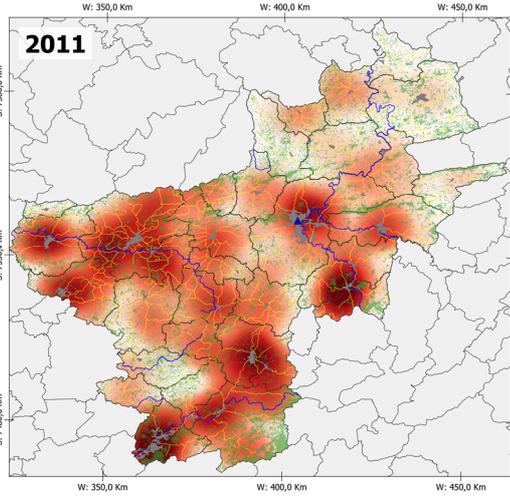


Figura 1.3 - Ocorrências anuais de intervenções antrópicas em APP na 1ª Regional



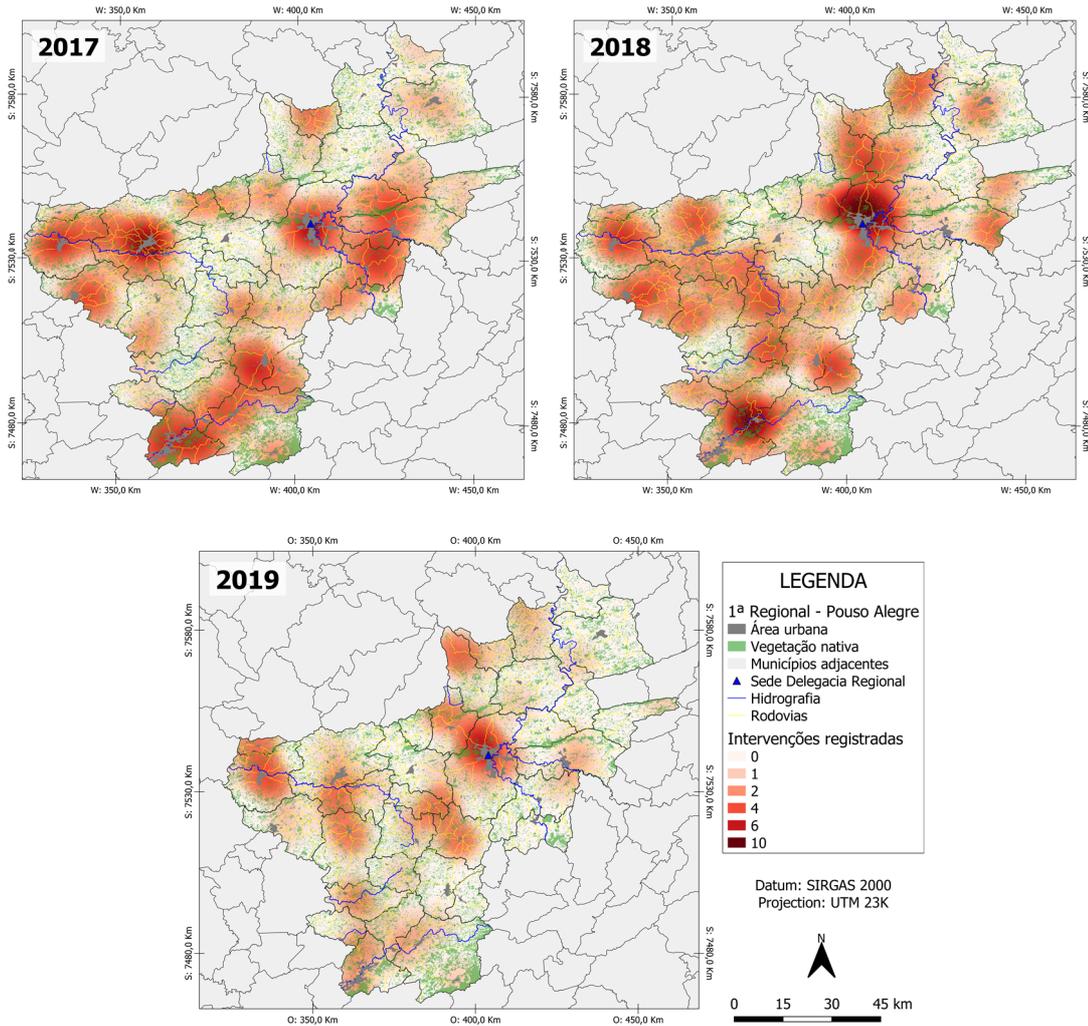


Figura 1.4 - Distribuição espacial das ocorrências anuais de intervenções antrópicas em APP na 1ª Regional de Pouso Alegre

Na análise da série temporal de ocorrências para a 1ª regional para diferentes modelos, disponíveis no APÊNDICE I – Testes de tendência 1ª regional, o melhor modelo testado para análise de tendência foi o quadrático. Na Figura 1.5 é possível observar a continuação da tendência de diminuição, observada nos últimos anos, no número de ocorrências na 1ª regional. Prevê-se que em 2021 e 2022 as ocorrências fiquem abaixo de 100.

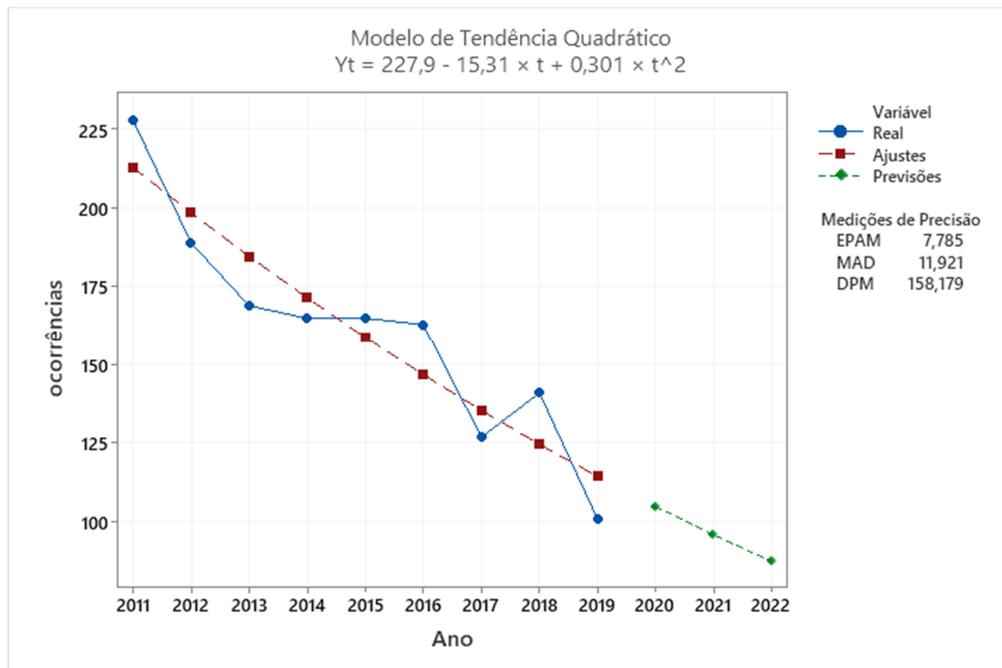


Figura 1.5 - Gráfico de análise de tendência na série temporal da 1ª regional com previsão de 3 anos

As ocorrências de intervenções anuais na 2ª Regional de São Lourenço são apresentadas na Figura 1.6. A média anual encontrada foi de 78,7 ocorrências considerando o período de 9 anos (2011-2019) dos dados, totalizando 708 ocorrências. Observa-se uma maior ocorrência de intervenções em APP em 2011 e 2015 com 94 e 90 registros, respectivamente. Embora não haja uma tendência na variação anual dos números de ocorrências reportadas no 17º Departamento, poucas ocorrências foram notadas em 2017 na 2ª Regional, assim como nos dados da 1ª Regional. Inversamente, um padrão espacial foi observado na concentração de intervenções antrópicas em APP que apresenta uma concentração de ocorrências próximas à localização da delegacia regional (Figura 1.7).

Diferentemente da 1ª Regional, a Regional de São Lourenço apresentou um aumento das ocorrências no ano de 2019. A maior variação nesse período foi no município de Cruzília, com aumento de 8 ocorrências. A maior variação do período total analisado (2011-2019) foi no município de Caxambu que, mesmo com a tendência de diminuição de casos em 2016, reportou um aumento de 9 ocorrências, tendo no ano anterior nenhuma ocorrência registrada.

Na porção Sul e Sudeste da 2ª Regional observa-se a ocorrência de intervenções em grandes áreas de vegetação nativa, onde se localiza o Parque Estadual da Serra do Papagaio e uma porção do Parque Estadual do Itatiaia. Não houve um padrão de distribuição com relação aos dados de rodovia e hidrografia

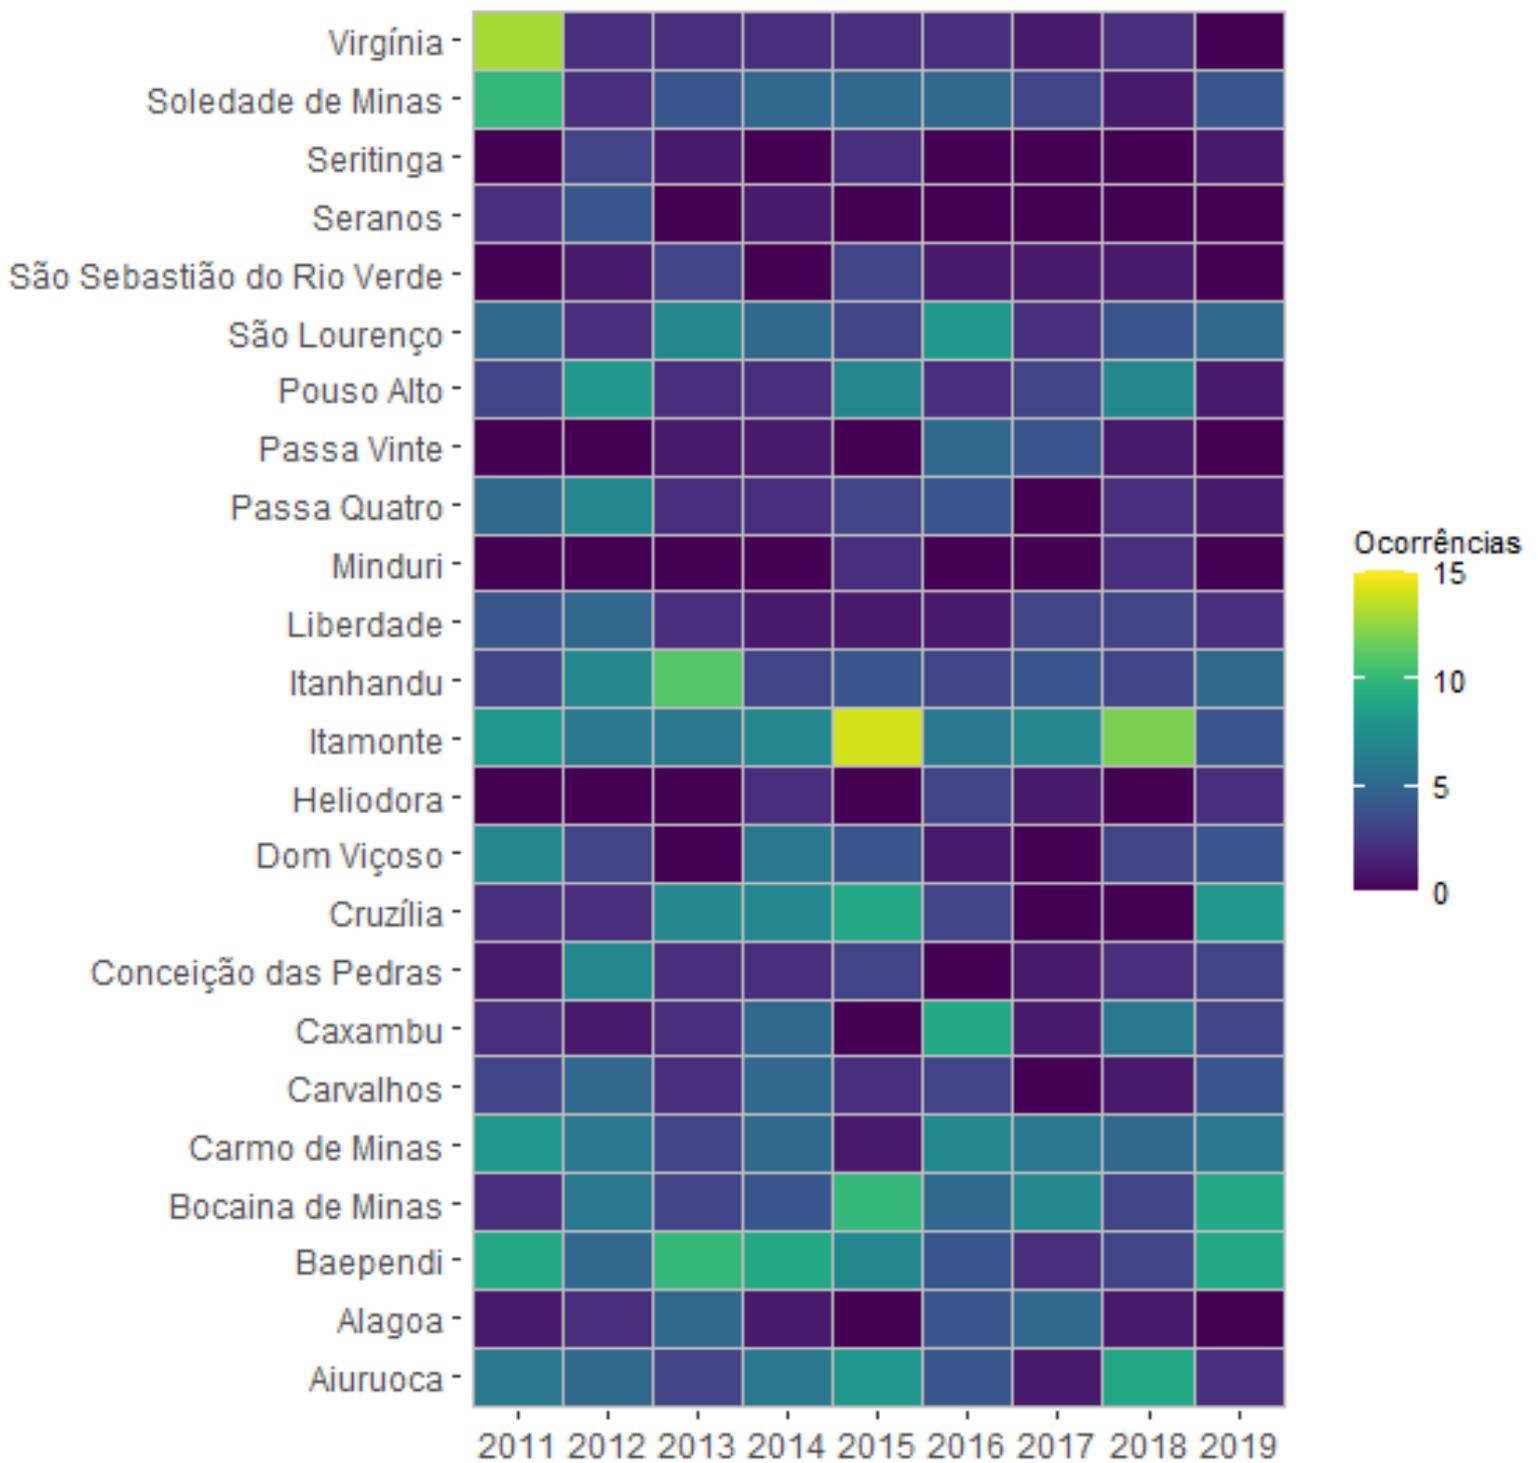
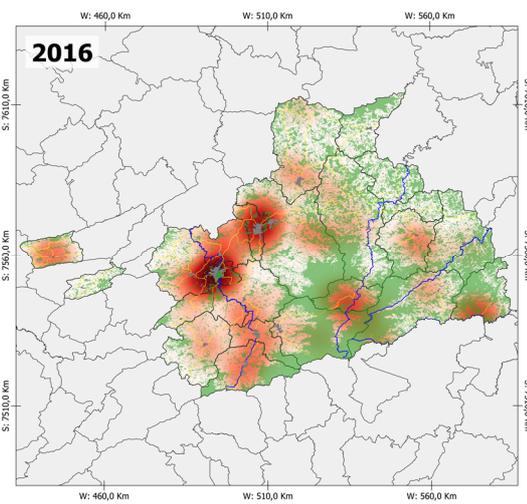
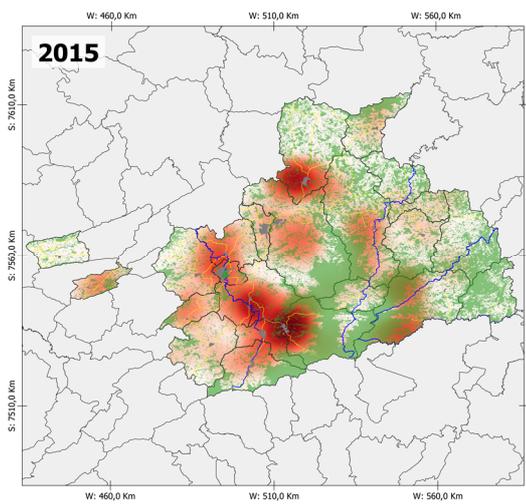
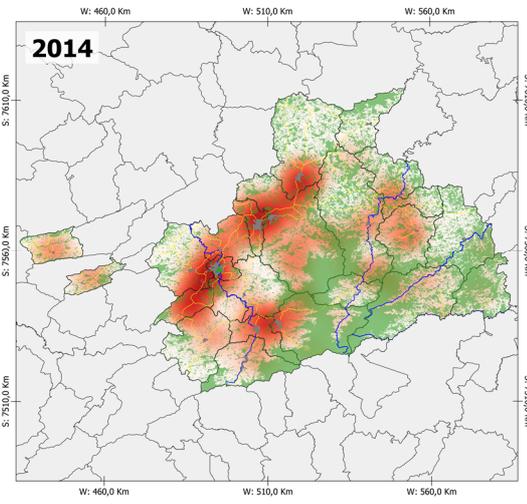
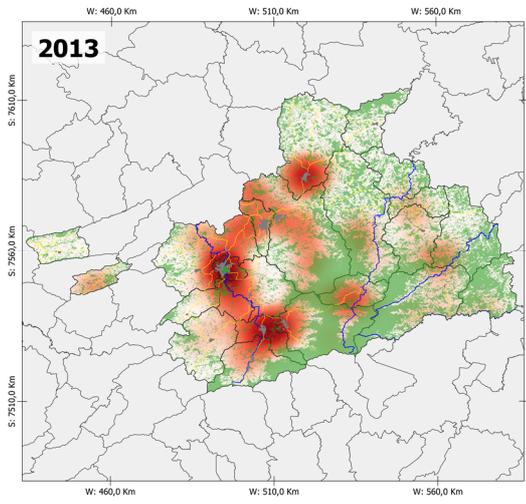
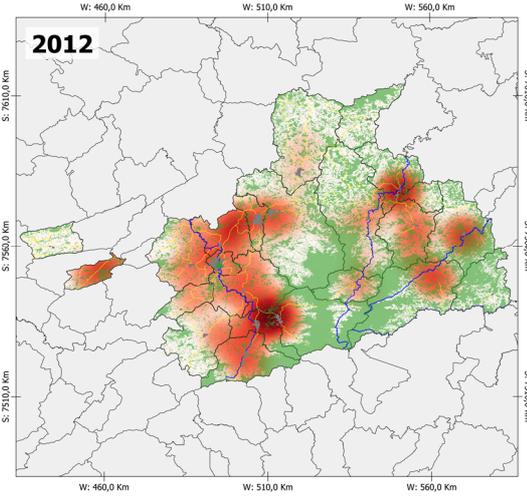
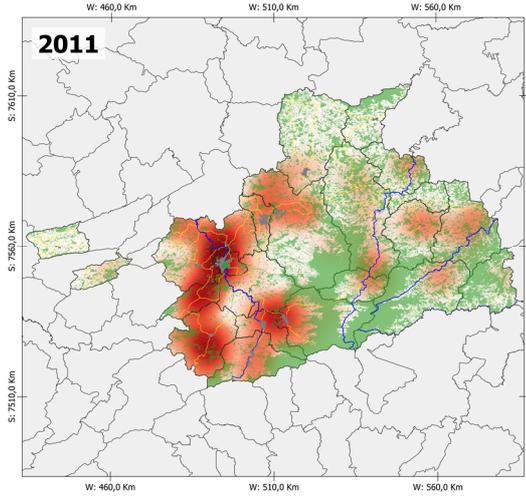


Figura 1.6 - Ocorrências anuais de intervenções antrópicas em APP na 2ª Regional



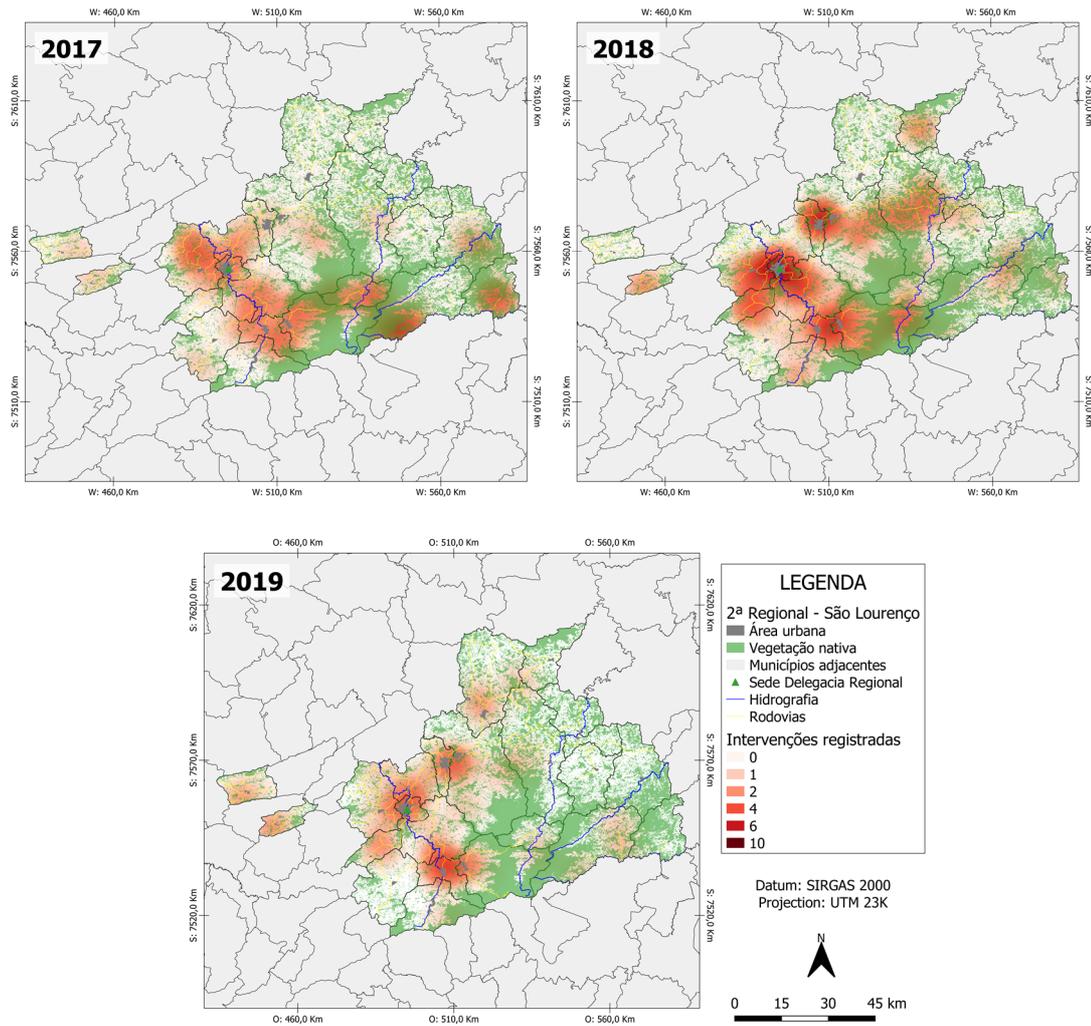


Figura 1.7 - Distribuição espacial das ocorrências anuais de intervenções antrópicas em APP na 2ª Regional de São Lourenço

O melhor modelo de análise de tendência para a série temporal da 2ª regional também foi o quadrático (APÊNDICE II – Testes de tendência 2ª regional). A Figura 1.8 apresenta a análise de tendência que aponta uma estabilização nas ocorrências, por volta de 67 ocorrências por ano a partir de 2021.

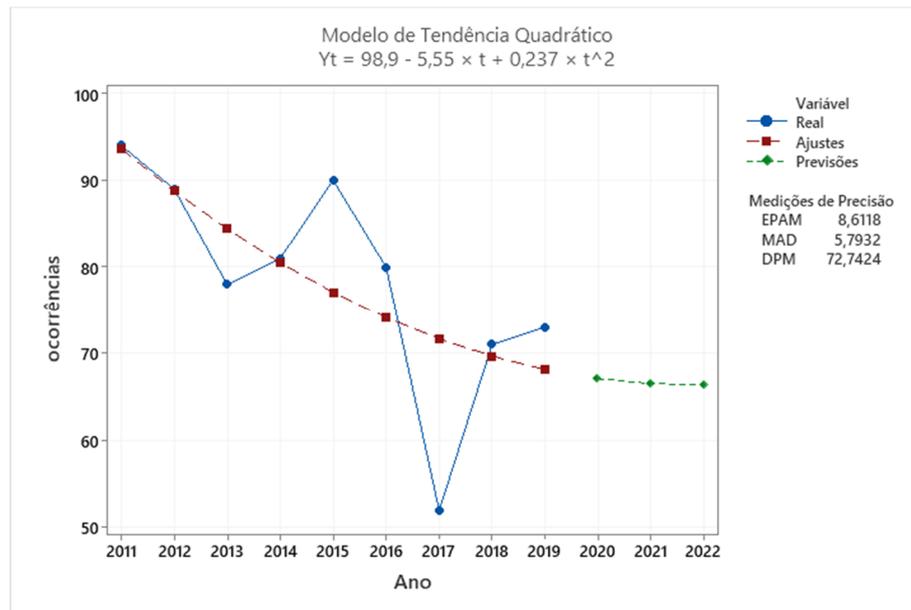


Figura 1.8 - Gráfico de análise da tendência na série temporal da 2ª regional com previsão de 3 anos

Em geral, as ocorrências de intervenções na 3ª Regional apresentadas na Figura 1.9 seguem o mesmo comportamento das outras regionais com altos índices de registros em 2011. O total de ocorrências foi de 650. Não obstante das variações observadas nos anos seguintes das regionais anteriores, os resultados obtidos indicam uma tendência de redução iniciada em 2012, com exceção do ano de 2015, nas ocorrências de intervenções antrópicas em APP na 3ª Regional (Figura 1.9). No ano de 2018 essa diminuição atingiu o patamar dos 66%, no qual obteve-se o menor número de ocorrências em todo o período avaliado, com exceção dos dados de 2019, em contrapartida à tendência de aumento nas ocorrências em 2018-2019 das outras regionais. A respeito dos padrões espaciais (Figura 1.10), verificou-se uma ocorrência similar às outras regionais durante o período 2011-2015, no qual houve um maior índice de ocorrências próximas à localização da delegacia regional, embora houve um declínio no número total de ocorrências observadas.

A maior variação encontrada na 3ª Regional foi no município de Cristina entre 2013-2014, com um aumento de 9 ocorrências. Em geral, as ocorrências se dispõem ao redor da Delegacia Regional de Itajubá, com alguns pontos de foco ao Leste/Nordeste da regional. Não há nenhum padrão espacial com relação aos dados de rodovia e hidrografia. Com relação às áreas de vegetação nativa, notou-se uma concentração anormal de ocorrências na zonal rural da divisa entre os municípios de Cristina e Maria da Fé em 2016, localizados no nordeste da regional.

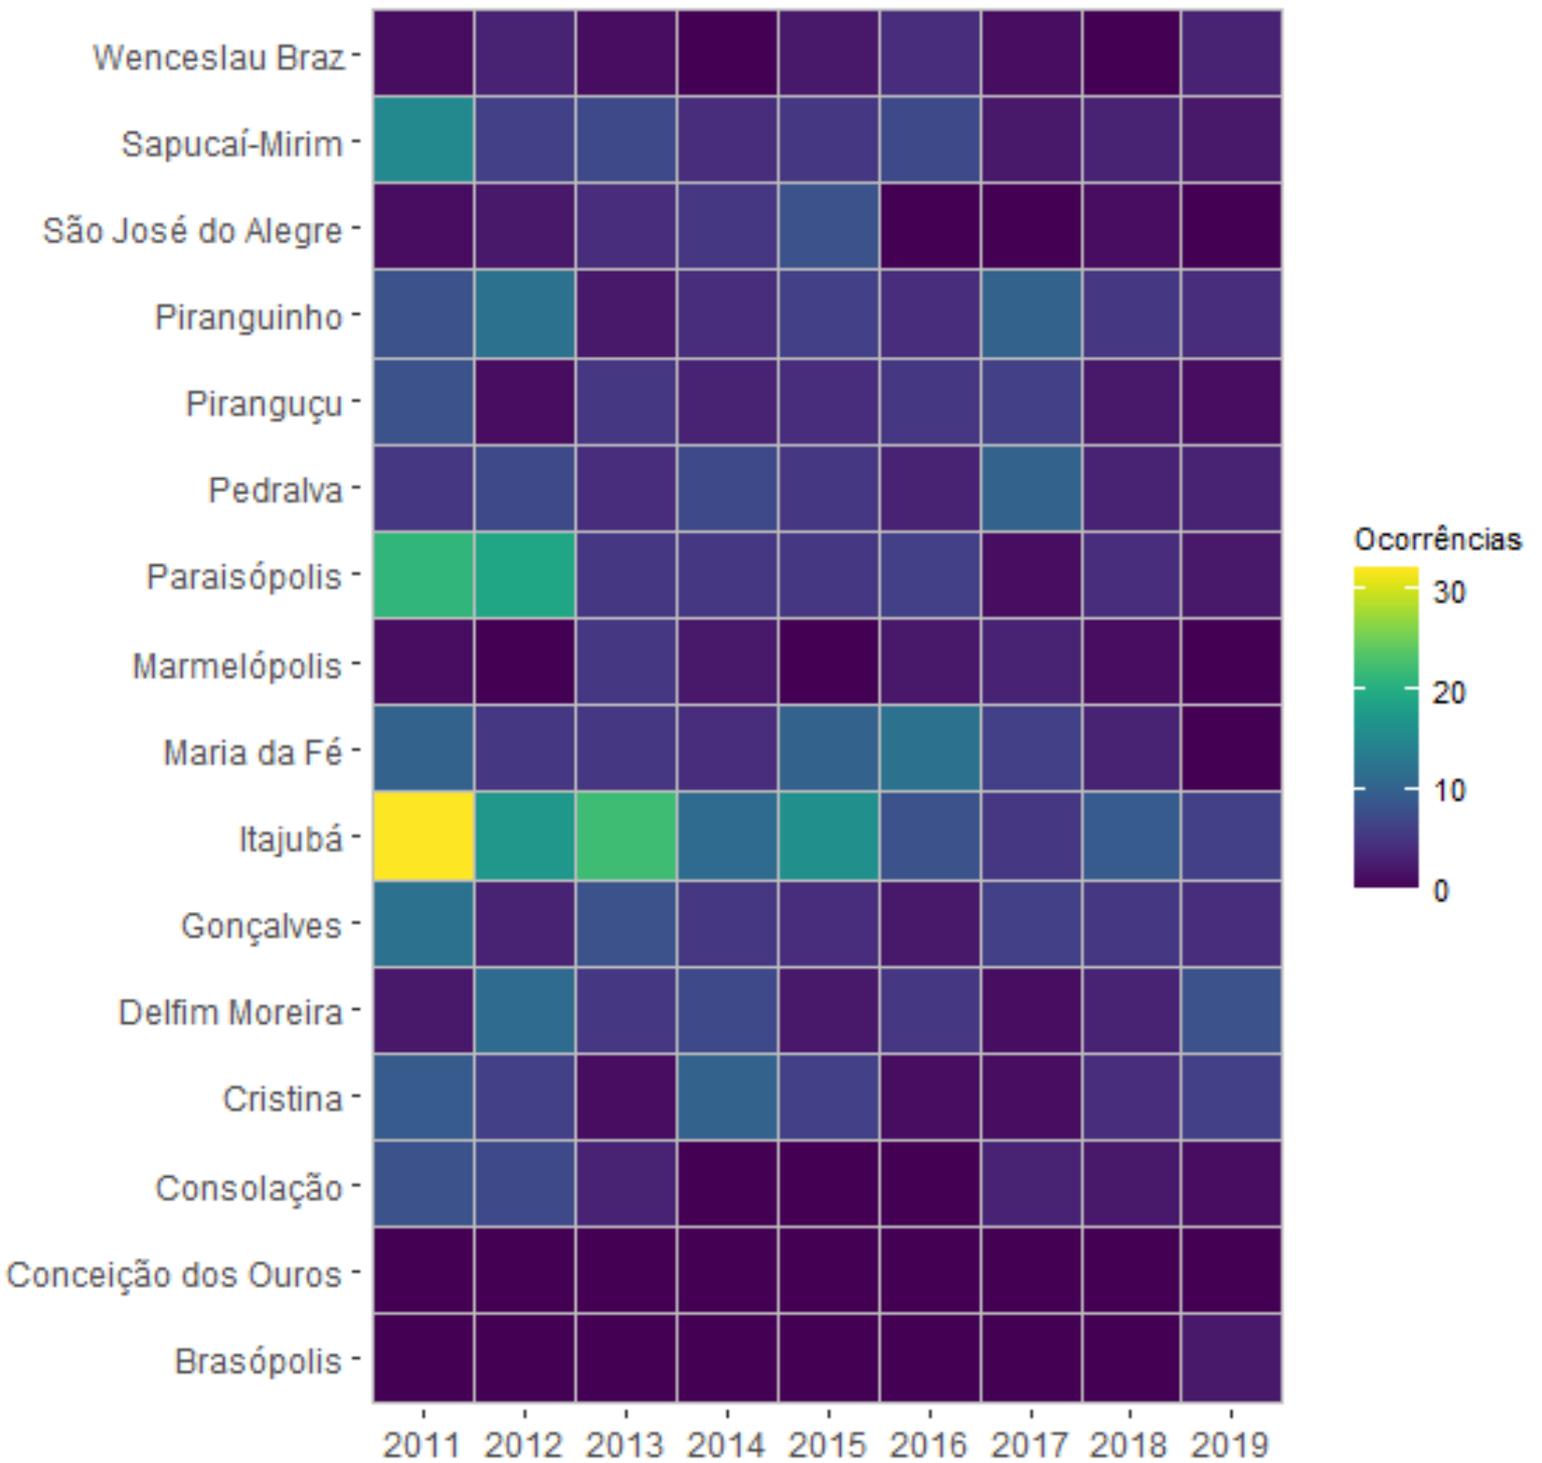
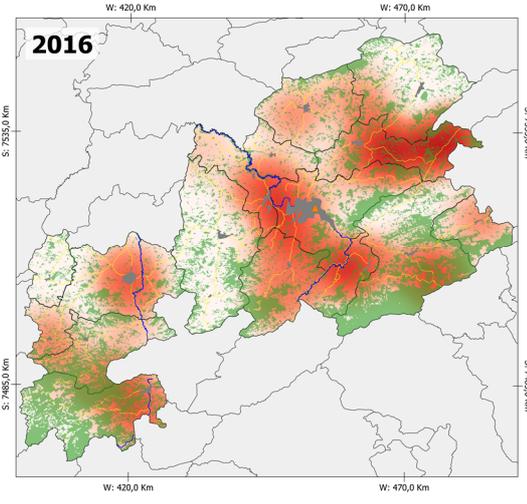
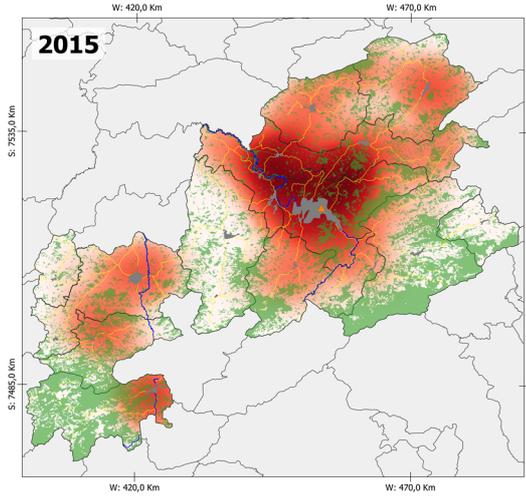
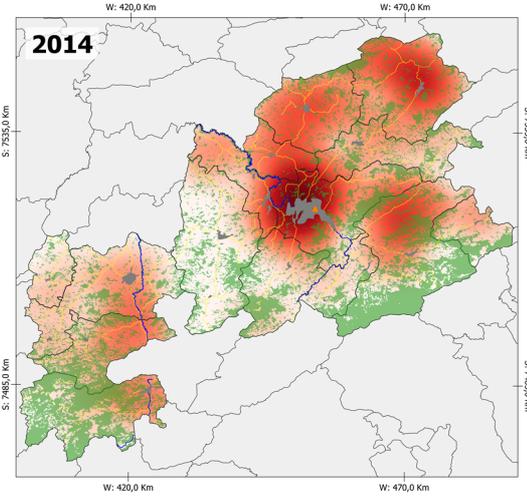
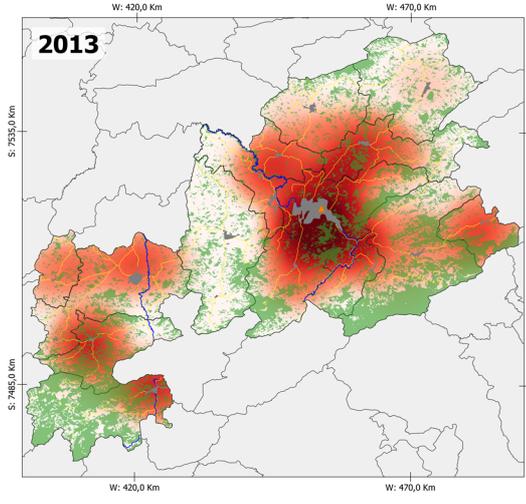
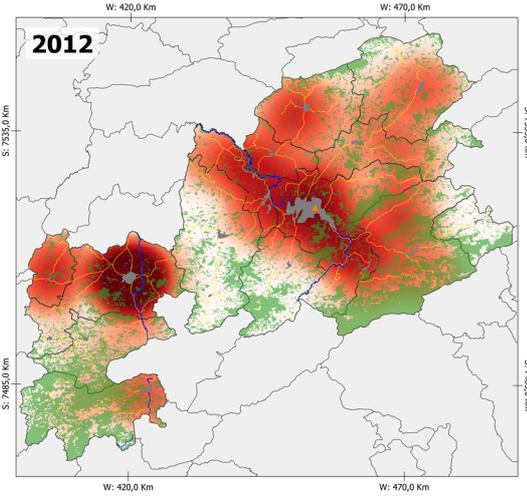
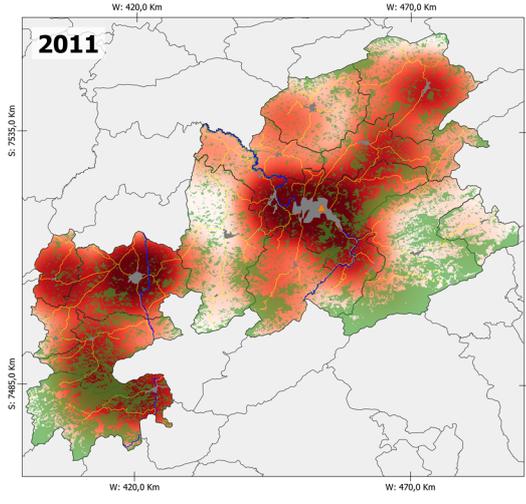


Figura 1.9 - Ocorrências anuais de intervenções antrópicas em APP na 3ª Regional



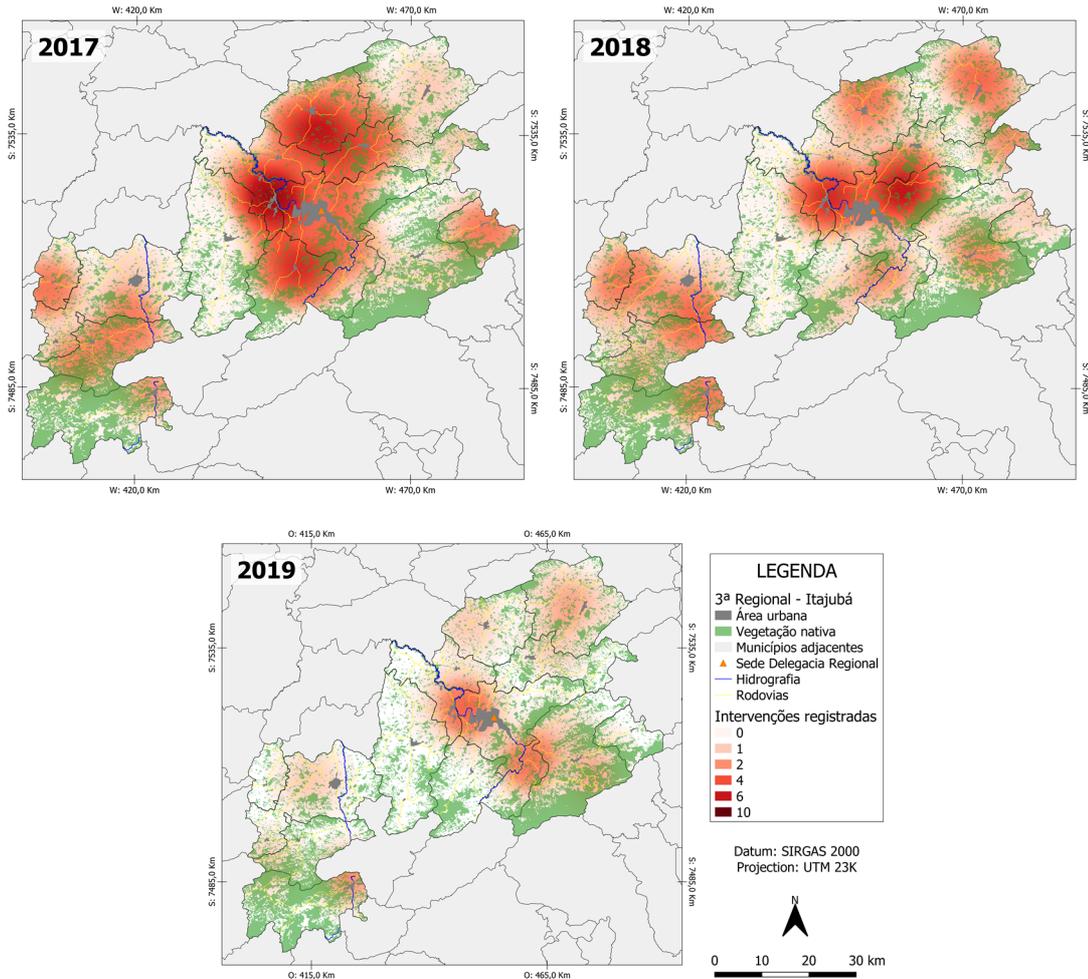


Figura 1.10 - Distribuição espacial das ocorrências anuais de intervenções antrópicas em APP na 3ª Regional de Itajubá

O modelo com melhor ajuste para a análise da série temporal da 3ª regional foi o de Curva S (APÊNDICE III – Testes de tendência 3ª regional). A Figura 1.11 mostra uma tendência de redução na quantidade de ocorrências da regional, atingindo um patamar de aproximadamente 30 ocorrências por ano.

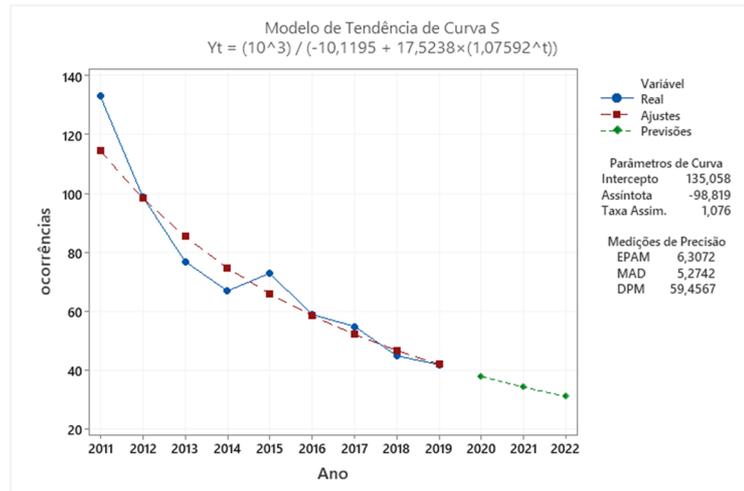


Figura 1.11 - Gráfico de análise da tendência na série temporal da 3ª regional com previsão de 3 anos

1.4. CONCLUSÕES

A rica biodiversidade encontrada no sul de Minas Gerais está sendo ameaçada por ações antrópicas. Posto que existem leis ambientais focadas na conservação do meio ambiente e sua biodiversidade, ações antrópicas em APP ainda ocorrem devido ao, principalmente, processo de urbanização e ao desenvolvimento não-sustentável. Embasado nos registros da Polícia Civil de MG, um total de 2.806 ocorrências de intervenções antrópicas em APP foram reportadas no período de janeiro de 2011 a dezembro de 2019. Esses dados foram traduzidos e descritos, por meio da estatística e análise espacial, com sucesso.

Uma maior frequência de focos de intervenções antrópicas foi encontrada na 1ª Regional devido à maior área de abrangência dos municípios. A análise temporal indicou uma redução nas ocorrências reportadas no ano de 2012 em comparação com 2011. Uma possível explicação para tal fato é a revisão no Código Florestal ocorrida em 2012 que trouxe mudanças e afrouxamentos nas leis de conservação e restauração de APP. A tendência de redução das ocorrências manteve-se para a 3ª Regional de Itajubá e atingiu o nível de 66% de redução em 2018, tornando-se o menor índice de intervenções antrópicas no período de 9 anos analisados. Os maiores aumentos, dentro de um ano, nas intervenções ocorreram nos municípios da Estiva e Pouso Alegre.

Nessa acepção, análises espaciais são indispensáveis para compreender os padrões nas ocorrências observadas pela Polícia Civil e aprimorar a eficiência do efetivo policial e coordenar a gestão com o intuito de otimizar o cumprimento das leis ambientais. Os resultados obtidos apontam para uma maior frequência de ocorrências próximas às áreas urbanas. Esse fato demonstra a possibilidade do efetivo da Polícia Civil se limitar às áreas dos centros

urbanos, seja por falta de recursos humanos, quanto por falta de recursos financeiros, uma vez que o corpo efetivo da Polícia Civil não cobre apenas ocorrências relacionadas ao meio ambiente, fato que contribui para a redução da efetividade do monitoramento de ocorrências em áreas mais remotas.

As análises estatísticas de tendências das regionais mostraram, com as previsões, uma propensão à redução no número de ocorrências de intervenções em APP. Essa tendência não representa a realidade, sob o prisma das APP estarem sendo preservadas, haja vista a fragilização das leis ambientais com o novo Código Florestal e a condição de fiscalização da Polícia Civil aqui descritas que provavelmente geram uma subnotificação (POSSAMAI; GONÇALVES, 2017); ademais, têm-se os relatórios da SOS Mata Atlântica (2019) que apontam para um crescente desmatamento em MG nos anos 2018-2019.

REFERÊNCIAS BIBLIOGRÁFICAS

ALTMANN, A.; STANTON, M. S. The densification normative of the ecosystem services concept in Brazil: Analyses from legislation and jurisprudence. **Ecosystem Services**, Amsterdam, v. 29, p. 282-293, 2018.

BRASIL. Constituição (1988). **Constituição da República Federativa do Brasil**. Brasília: Senado Federal, Centro Gráfico, 1988a.

BRASIL. 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. **Diário Oficial da União**, Brasília, DF, 13 fev. 1988b.

CAMPAGNOLO, K.; SILVEIRA, G. L.; MIOLA, A. C.; SILVA, R. L. L. Área de preservação permanente de um rio e análise da legislação de proteção da vegetação nativa. **Ciência Florestal**, Santa Maria, v. 27, n. 3, p. 831-842, 2017.

EDELMAN, D. J.; SCHUSTER, M.; SAID, J. Urban Environmental Management in Latin America, 1970- 2017. **Current Urban Studies**, Wuhan, v. 5, n. 3, p. 305-331, 2017.

EMBRAPA. **Áreas Urbanas no Brasil em 2015**, 2015. Geoinfo. Disponível em: http://geoinfo.cnpm.embrapa.br/layers/geonode%3Aareas_urbanas_br_15. Acesso em: 20 out. 2020.

FREITAS, E. P.; MORAES, J. F.; STORINO, M. Indicadores ambientais para áreas de preservação permanente. **Agriambi**, Campina Grande, v. 17, n.4, p. 443-449, 2013.

IBGE. **Cidades**, 2017. Página Inicial. Disponível em: cidades.ibge.gov.br. Acesso em: 28 nov. 2019.

IBGE. **Logística de transportes no Brasil**, 2014. Brasil: Redes geográficas. Disponível em: <https://www.ibge.gov.br/geociencias/cartas-e-mapas/redes-geograficas/15793-logistica-dos-transportes.html?=&t=downloads>. Acesso em: 21 out. 2020.

MINITAB. **Interpretar todas as estatísticas e gráficos para Análise de tendências**, 2019. Suporte ao Minitab 18. Disponível em: <https://support.minitab.com/pt-br/minitab/18/help-and->

how-to/modeling-statistics/time-series/how-to/trend-analysis/interpret-the-results/all-statistics-and-graphs/#mape. Acesso em: 01 mar. 2021

POSSAMAI, G.; GONÇALVES, T. M. Código Florestal Brasileiro de 2012: contexto e cenário de sua aprovação – uma análise sociopolítica. **Revista Direito Ambiental e Sociedade**, Caxias do Sul, v.7, n.3, p. 231-264, 2017.

QGIS. **Quantum Geographic Information System (QGIS) Software**. Versão 3.6.2. Open Source Geospatial Foundation Project: Beaverton, 2019.

RIBEIRO, R. E. Crimes Ambientais registrados pela Polícia Civil no Distrito Federal: uma análise entre os anos de 2009 e 2015. **Revista Brasileira de Criminalística**, Brasília, v. 6, n. 1, p. 7-13, 2017.

SAURET, G. V. **Estatísticas pela vida: a coleta e análise de informações criminais como instrumentos de enfrentamento da violência letal**. Recife: Bagaço Desing, 2012.

SISEMA. **Infraestrutura de Dados Espaciais do Sistema Estadual de Meio Ambiente e Recursos Hídricos**. Belo Horizonte: IDE-Sisema, 2019. Disponível em: idesisema.meioambiente.mg.gov.br. Acesso em: 28 out. 2020.

SOARES-FILHO, B.; RAJÃO, R.; MACEDO, M.; CARNEIRO, A.; COSTA, W.; COE, M.; RODRIGUES, H.; ALENCAR, A. Cracking Brazil's Forest Code. **Science**, Washington, v. 344, n. 6182, p. 363–364, 2014.

SOS MATA ATLÂNTICA. **Atlas dos Remanescentes Florestais da Mata Atlântica**. São Paulo: Fundação SOS Mata Atlântica, 2019. Disponível em: <https://www.sosma.org.br/wp-content/uploads/2019/10/Atlas-mata-atlanticaDIGITAL.pdf>. Acesso em: 30 jan. de 2020.

SPATIALITE. **Spatialite Open Source Library**. Versão 4.3.0. Territorial and Environmental Information System Regione Toscana: Toscana, 2015.

STAN, K.; SANCHEZ-AZOFEIFA, A.; ESPÍRITO-SANTO, M.; PORTILLOQUINTERO, C. Simulating deforestation in Minas Gerais, Brazil, under changing government policies and socioeconomic conditions. **PloS one**, San Francisco, v. 10, n. 9, p. e0137911, 2015.

TANIWAKI, R. H.; FORTE, Y. A.; SILVA, G. O.; BRANCALION, P. H.; COGUETO, C. V.; FILOSO, S.; FERRAZ, S. F. The Native Vegetation Protection Law of Brazil and the challenge for firstorder stream conservation. **Perspectives in Ecology and Conservation**, Amsterdam, v. 16, n. 1, p. 49-53, 2018.

CAPÍTULO II

MAPEAMENTO DE INTERVENÇÕES ANTRÓPICAS EM APP NO SUL DE MINAS POR MEIO DE ANÁLISE ORIENTADA A OBJETOS

RESUMO

A Mata Atlântica é o bioma brasileiro mais desmatado com apenas 12,4% da vegetação nativa restante, sendo Minas Gerais o estado com a maior concentração de fragmentos remanescentes. Todavia, Minas Gerais também foi o estado que mais desmatou esse bioma entre 2018-2019. Nessa acepção, o monitoramento do desmatamento no estado é essencial para a preservação do meio ambiente. Uma das ferramentas legais brasileiras para a preservação de recursos ambientais são as Áreas de Preservação Permanente (APP). À vista disso, esse estudo investigou o município do Sul de Minas Gerais com maior alteração quantitativa de intervenções antrópicas em APP. Esse mapeamento foi realizado pelo uso de uma classificação com análise orientada a objetos (GEOBIA) nas imagens do Sentinel-2, com aplicação de conceitos de *Data Mining* e *Machine Learning*. Os resultados foram submetidos à análise estatística e avaliação de precisão e acurácia. Inferiu-se uma variação negativa de vegetação arbórea em junho de 2018. Foram detectadas 0,74 km² de mudanças no uso do solo de APP nesse mês, distribuídos em 3043 pontos. Os 138 pontos de variação negativa maiores que 1000 m² são os que devem receber atenção do órgão fiscalizador. A árvore de decisão obteve desempenho equilibrado (PRC e ROC próximos de 1) e satisfatório (Índice Kappa de 0,9072; *F-Measure* médio de 0,926; MMC médio de 0,908), com apenas uma classe (cultivo) com confusão significativa na matriz de erros. A metodologia proposta, ao se cruzar a classificação com o banco de dados da Polícia Civil, foi capaz de identificar um número maior de mudanças em vegetação próximas à APP. Imagens com melhores resoluções podem contribuir para a melhoria da identificação. Espera-se que esse estudo sirva de embasamento para uma gestão mais eficiente dos recursos da Polícia Civil no combate ao desmatamento da região.

Palavras-chave: Sensoriamento Remoto; SIG; Estatística; Bioma Mata Atlântica.

2.1. INTRODUÇÃO

O bioma Brasileiro Mata Atlântica é uma das maiores concentrações de biodiversidade mundial (LEÃO *et al.*, 2014). Este também é o bioma brasileiro mais desmatado, cerca de 12,4% da floresta original ainda permanece, o equivalente a uma área de 16,3 milhões de hectares. O estado de Minas Gerais (MG) é o estado com maior porcentagem de remanescentes do bioma Mata Atlântica com cerca de 17 % (2,8 milhões de hectares). O último boletim da ONG SOS Mata Atlântica aponta que entre 2018-2019 houve um aumento de 27,2% de desmatamento em relação ao período anterior de 2017-2018. MG apresentou a maior taxa de desmatamento (4.972 hectares) entre os estados (SOS MATA ATLÂNTICA, 2019).

Devido esse crescente desmatamento, um monitoramento efetivo se faz necessário para subsidiar os esforços do Estado em proteger o meio ambiente. Uma das áreas a serem protegidas são as Áreas de Proteção Permanente (APP), instauradas pelo Código Florestal Brasileiro de 1965 (Lei nº 4.771 de 16 de setembro de 1965) e atualizadas pelo novo Código Florestal Brasileiro de 2012 (Lei nº 12.651 de 25 de maio de 2012) (RIBEIRO, 2011). De acordo com Art. 3, Inciso II, as APP são áreas protegidas, podendo ser cobertas por vegetação nativa ou não, com a função ambiental de proteger o solo, de resguardar a biodiversidade, a paisagem e os recursos hídricos, além de facilitar o fluxo gênico da fauna e flora e assegurar o bem-estar da sociedade (BRASIL, 2012).

Recursos de geotecnologias vem sendo utilizados em variados estudo para a identificação de desmatamento em diversas áreas do Brasil (CLEMENTE; ESPIRITO-SANTO; LEITE, 2020; COSTA *et al.*, 2019; PORANGABA; AMORIM, 2019). As geotecnologias são um suporte à tomada de decisão e planejamento dos órgãos públicos e privados responsáveis por essa proteção (RAMOS; NÓBREGA, 2020).

Uma das geotecnologias mais utilizada para esse fim é o Sensoriamento Remoto (SR). O SR permite varrer uma vasta área de modo mais rápido e sem a necessidade de um extenso trabalho de campo (SÁNCHEZ, 2013). Um dos produtos possíveis do Sensoriamento Remoto é a classificação supervisionada de imagens de satélite. Por anos essas classificações foram feitas pelo método baseado em pixels (*pixel-based*), muito difundido e que gera resultados satisfatórios em imagens de baixa resolução (CECCARELLI *et al.*, 2013). Em imagens de média a alta resolução, a tradicional classificação não se mostrou suficiente (BLASCHKE, 2010; MYINT *et al.*, 2011). Por conseguinte, surge uma alternativa para suprir a necessidade de uma melhor classificação para essas imagens. A Análise Orientada a Objetos, do termo em

inglês OBIA ou GEOBIA, é um método iterativo com uso de regras e funções hierárquicas que segmenta as imagens de satélite em objetos homogêneos, de acordo com a forma, tamanho, textura e características espectrais (BLASCHKE, 2010; BLASCHKE *et al.* 2014; MACHALA; ZEDJDOVÁ, 2017). Com isso a GEOBIA está se tornando mais popular no meio acadêmico e em aplicações que visam a extração de informação de imagens devido às suas vantagens (BLASCHKE *et al.* 2014).

Tecnologias computacionais podem auxiliar no processo de GEOBIA e destaca-se dentre elas o *Data Mining* e *Machine Learning*. A mineração de dados consiste no processo exploratório dos dados para a extração de relações sistêmicas entre as variáveis (SOUZA; KUX, 2014). Esse processo corresponde à aplicação de algoritmos capazes de extrair informações e estes podem ser de origem descritiva, agrupamento, predição associação ou detecção de anomalias (CASTRO; FERRARI, 2016). Já o *Machine Learning* ou Aprendizado de Máquina, corresponde a uma série de métodos que computadores utilizam para melhorar e realizar predições no comportamento nos dados (MOLNAR, 2020). A árvore de decisão é um dos métodos supervisionados de *Machine Learning*, onde o usuário insere um grupo de amostras de treinamento e, a partir desse conjunto, o computador classifica um banco de dados (GRIFFITH; HAY, 2018). O algoritmo C4.5, desenvolvido por Quinlan (1996), é amplamente utilizado para métodos de indução de árvore de decisão e foi adaptado para a linguagem JAVA sob o nome J48 (VIEIRA *et al.*, 2018).

O município de Pouso Alegre está inserido na 1ª Regional do 17º Departamento da Polícia Civil. Na análise dos dados da Polícia Civil (Capítulo I), essa regional demonstrou o maior índice de ocorrências de intervenções antrópicas em APP. Dentro da 1ª regional, o município de Pouso Alegre apresentou a maior variação anual do número de ocorrências em APP no período recente de 2016-2019. No ano de 2018, o mês com maior incidência de intervenções em APP no município foi junho.

Nesse contexto, o objetivo desse estudo foi investigar, de forma semiautomática pelo uso da GEOBIA e de tecnologias como *Data Mining* e *Machine Learning*, as intervenções antrópicas em APP no município de Pouso Alegre em junho de 2018 e prover as análises para a sociedade de forma a contribuir no combate ao desmatamento.

2.2. MATERIAIS E MÉTODOS

2.2.1. Área de estudo

O estudo foi realizado no município de Pouso Alegre, localizado no sul de Minas Gerais e pertencente à 1ª Regional do 17º Departamento da Polícia Civil/MG. A Figura 2.1 retrata a localização espacial do município dentro da 1ª Regional, formada por 33 municípios.

Pouso Alegre se situa nas coordenadas 22°14'36''S e 45°55'48'' (RAIMUNDO *et al.*, 2017); possui população estimada de 152.549 pessoas para 2020, com uma área de unidade territorial de 542,79 km² e densidade demográfica de 281,04 hab/km², e está inserido no bioma da Mata Atlântica (IBGE, 2017). O município é o segundo mais populoso da região e o décimo quarto do estado (FILHO *et al.*, 2018).

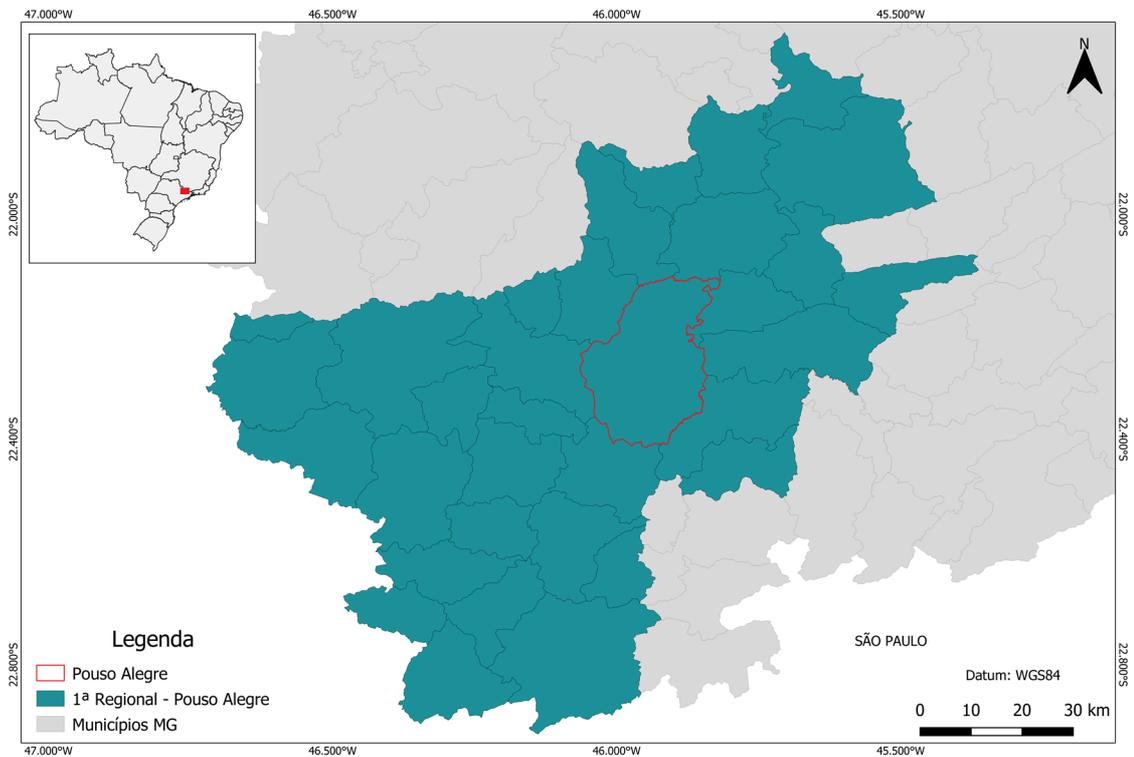


Figura 2.1 - Localização da 1ª Regional de Pouso Alegre sob o comando do 17º Departamento da Polícia Civil de Minas Gerais, Brasil

2.2.2. Metodologia

O fluxograma da Figura 2.2 esquematiza o processo lógico da metodologia desse trabalho.

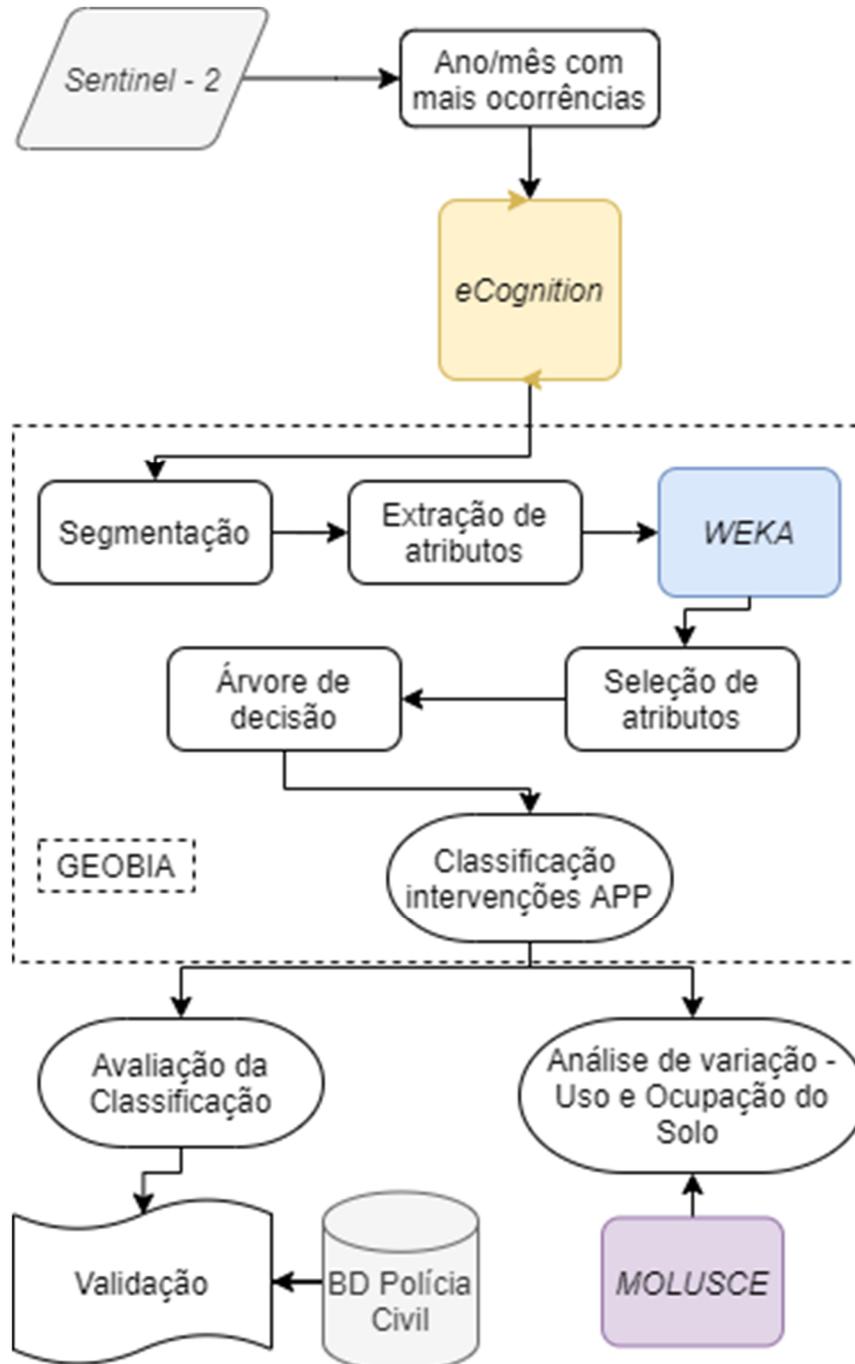


Figura 2.2 - Fluxograma da metodologia aplicada

2.2.2.1. Aquisição de Imagens

O primeiro passo foi a escolha do mês para esse estudo. As datas foram escolhidas com base nos resultados do Cap. I (Seção 1.3) que indicaram as maiores taxas de variação para os municípios de Estiva e de Pouso Alegre. Como as imagens do Sentinel-2 só estão disponíveis a partir de Set/2016, foi escolhida a variação referente ao município de Pouso Alegre, que ocorre em 2018. Dentro do ano de 2018 para Pouso Alegre, os meses com maior número de

ocorrências foram setembro e junho, ambos com 4 ocorrências. Devido à grande presença de nuvens nas imagens do Sentinel-2 no mês de setembro, adotou-se o mês de junho para a análise proposta.

A Figura 2.3 mostra a posição geográfica das ocorrências em Pouso Alegre no mês de junho/2018. A Figura 2.4 apresenta as proximidades de cada ocorrência.

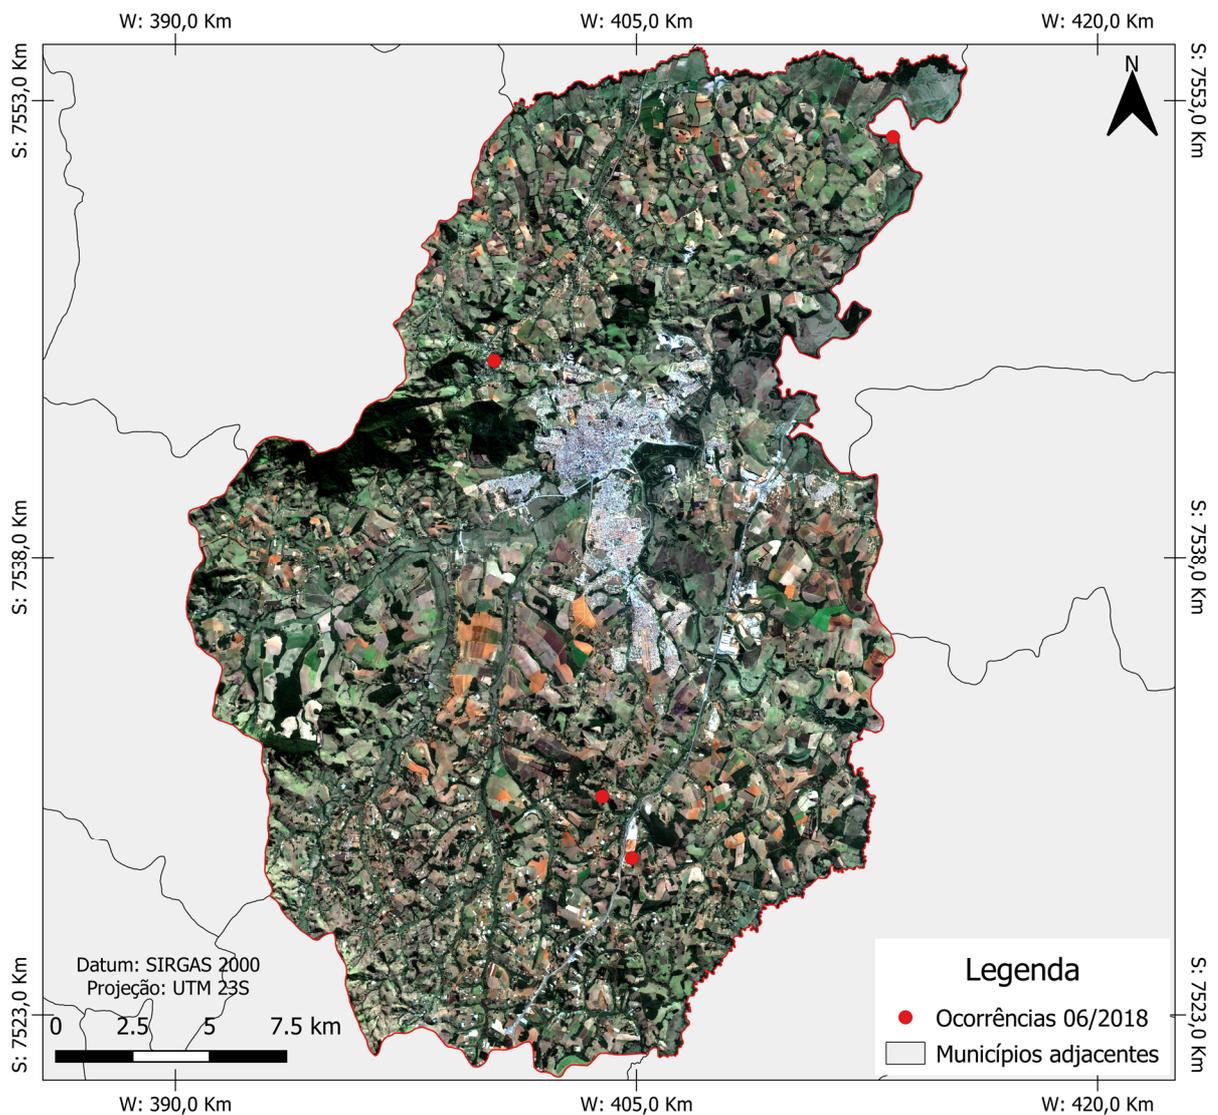


Figura 2.3 – Mapa de localização das ocorrências do mês de junho no município PA

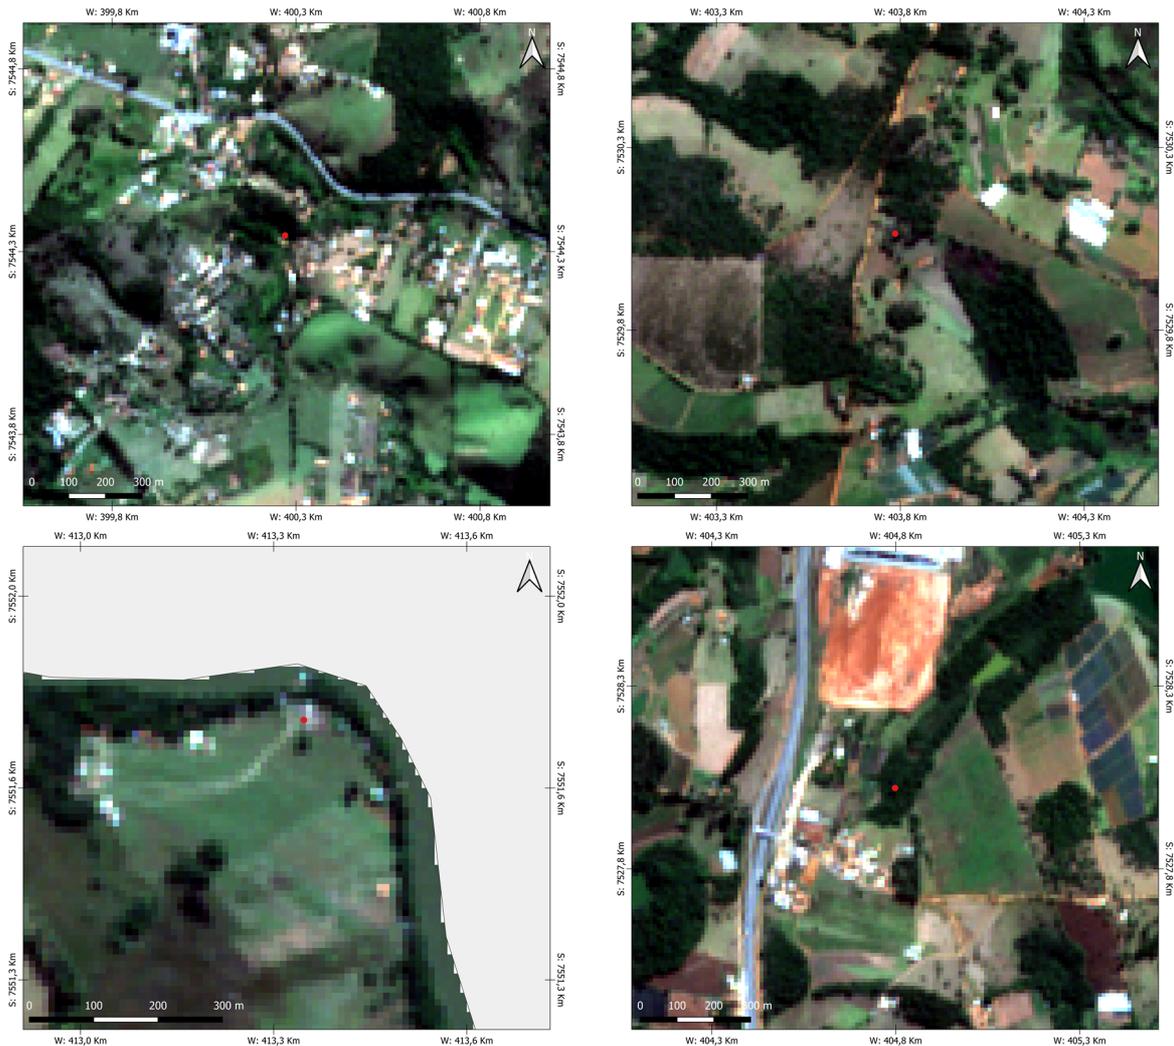


Figura 2.4 – Proximidades das ocorrências do mês de junho em PA

As imagens do Sentinel-2 nível-1C foram baixadas pela plataforma aberta do *Copernicus* nas datas iniciais do mês escolhido e seu sucessor (01/06/2018 e 01/07/2018) (ESA, 2020). As imagens foram reprojctadas e colocadas em mosaico para o recorte com os limites do município. Uma composição colorida RGB com as bandas 432 (cor natural) foi realizada para os meses escolhidos.

2.2.2.2. Segmentação

As imagens do Sentinel-2 foram inseridas no *software* eCognition 9.0.1 e segmentadas de acordo com os mesmos parâmetros para as duas imagens. Utilizou-se o algoritmo *Multiresolution* com o parâmetro de escala = 30, parâmetro de forma = 0,1 e parâmetro de compacidade = 0,5. O parâmetro de escala é responsável por determinar o limite de heterogeneidade dos objetos entre si. Um maior parâmetro de escala gera uma segmentação mais detalhada e com um volume maior de objetos (ZHENG, 2015). O parâmetro de forma rege

a irregularidade do formato dos objetos, por uma ponderação entre heterogeneidade e suavidade, sendo que valores maiores geram objetos mais regulares (ZHENG, 2015). O parâmetro de compacidade controla a suavidade dos limites do objeto. Valores maiores resultam em objetos com limites mais brandos (ZHENG, 2015).

2.2.2.3. Extração de atributos

A extração de atributos é realizada após a segmentação e criação dos objetos geográficos de acordo com as características espectrais, forma e semelhança aos objetos vizinhos. Amostras foram tomadas para 5 classes diferentes: área construída, cultivo, solo exposto, vegetação arbórea e vegetação rasteira. Foram obtidas 4228 amostras distribuídas aleatoriamente ao longo da imagem de Junho.

Nas duas imagens foram extraídos 43 atributos dos objetos geográficos, apresentados na Tabela 2.1 abaixo. A escolha dos atributos espectrais, geométricos e hierárquicos das amostras se deu pelo conhecimento do especialista (BLASCHKE *et al.*, 2014).

Tabela 2.1 - Atributos das imagens do mês de junho e julho utilizados na mineração de dados

Nº	Atributos
1	Ratio R
2	Ratio B
3	Ratio G
4	Ratio NIR
5	GLCM Homogeneity R
6	GLCM Homogeneity G
7	GLCM Homogeneity B
8	GLCM Homogeneity NIR
9	GLDV Entropy R
10	GLDV Entropy G
11	GLDV Entropy B
12	GLDV Entropy NIR
13	Contrast to neighbor pixels R
14	Contrast to neighbor pixels G
15	Contrast to neighbor pixels B
16	Contrast to neighbor pixels NIR
17	Visible Brightness
18	NDVI
19	Min. Pixel value R
20	Min. Pixel value G
21	Min. Pixel value B
22	Min. Pixel value NIR
23	Max. Pixel value R
24	Max. Pixel value B
25	Max. Pixel value G

26	Max. Pixel value NIR
27	Max. Difference
28	Standard Deviation R
29	Standard Deviation G
30	Standard Deviation B
31	Standard Deviation NIR
32	Mean R
33	Mean G
34	Mean B
35	Mean NIR
36	Mean difference R
37	Mean difference G
38	Mean difference B
39	Mean difference NIR
40	Compactness
41	Brightness
42	Border index
43	Class name

2.2.2.4. Seleção de atributos

A seleção dos atributos mais importantes para a classificação das imagens se deu pela mineração de dados (*Data Mining*) e *Machine Learning* executados no *software* WEKA versão 3.8.5.

As amostras são exportadas do eCognition no formato .csv. Para a inserção dos dados no WEKA, é preciso adequá-los, realocando algumas colunas e convertendo o formato para .arff. Para tal, utilizou-se o *software* RStudio 1.4.1103 que, por meio de *scripts* na linguagem de programação R disponíveis no APÊNDICE IV – *Script* de formatação dos dados para inserção no *software* WEKA, executou os ajustes necessários.

A mineração de atributos se deu pela seleção do algoritmo da árvore de decisão, que seleciona os atributos mais relevantes para aquela classificação.

2.2.2.5. Árvore de decisão

A árvore de decisão é um modelo hierárquico com aplicação em diversas áreas do conhecimento devido à sua capacidade preditiva e à sua resolução de problemas de forma simples e objetiva (VIEIRA *et al.*, 2018). Os modelos preditivos gerados pelas árvores de decisão têm sido usados como suporte a tomadas de decisão, em razão de segmentar dados heterogêneos de acordo com suas similaridades de maneira a agrupá-los em grupos mais homogêneos em relação à variável alvo (RAMYA *et al.*, 2015). Um exemplo de árvore de

decisão é apresentado na Figura 2.5. A estrutura de uma árvore de decisão é composta por nós, ramos e folhas. Os nós são as regiões de separação dos dados pelos testes lógicos, sendo o primeiro nó chamado de nó-raiz, do qual se originam os nós internos. Os ramos são os valores dos atributos de saída de um nó que se conectam ao nó filho ou nó interno. As folhas, ou nós terminais, são as regiões associadas a um rótulo de valor (SATO *et al.*, 2013). O banco de dados entra pelo nó-raiz e um atributo (variável decisória) é apresentada; dependendo do resultado lógico, são criadas duas folhas ou nós internos e a árvore vai se ramificando até que se alcance uma folha que apresente a variável de decisão (MEDEIROS *et al.*, 2014).

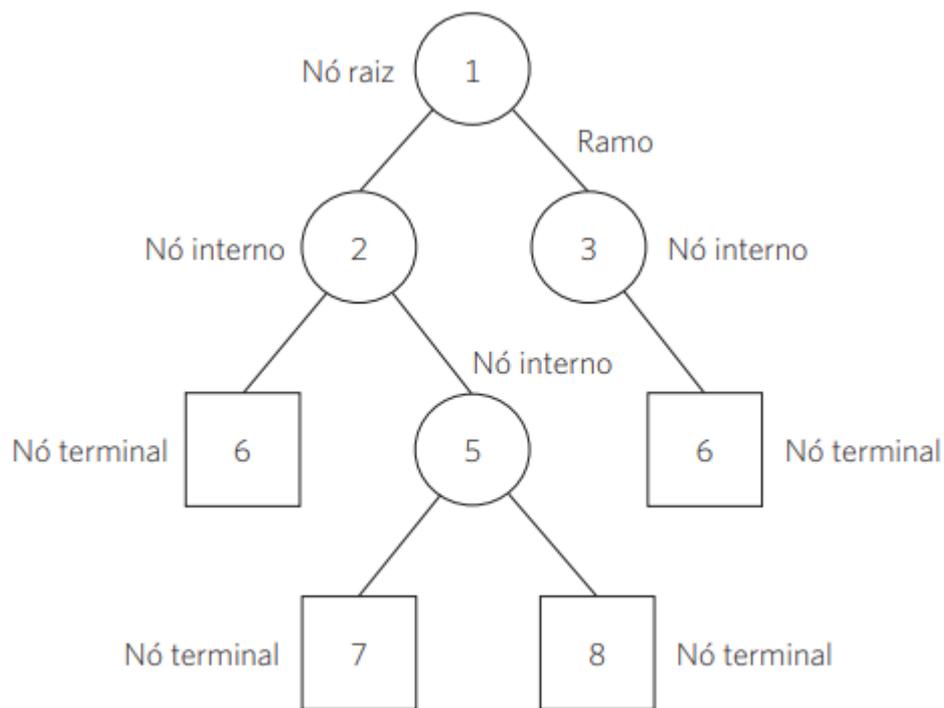


Figura 2.5 – Esquema de uma árvore de decisão. Medeiros *et al.* (2014).

Uma árvore de decisão foi gerada, por meio validação cruzada com 10 pastas, selecionando atributos das amostras pela mineração de dados, disponível no APÊNDICE V – Árvore de decisão. O desempenho da árvore foi avaliado. O algoritmo classificador para a geração das árvores foi o J48, uma versão de código aberto do algoritmo C4.5. Por meio desse algoritmo, é possível analisar o caminho decisório do computador para a classificação. Os parâmetros utilizados de fator de confiança e número mínimo de instâncias por folha foram, respectivamente, 0,25 e 2.

2.2.2.6. Classificação

A árvore de decisão das amostras foi utilizada para a classificação do total de objetos para cada mês. O resultado é dado em .csv. Para a exportação, foram utilizados os *scripts* no

RStudio dispostos no APÊNDICE VI – *Scripts* de exportação da classificação que adicionaram a informação da classificação no *shapefile* dos objetos da etapa da segmentação.

Os resultados foram espacializados no QGIS 3.10.12 a fim de confeccionar os mapas temáticos.

2.2.2.7. Avaliação

Os mapas temáticos foram avaliados, por meio de validação cruzada, de acordo com os índices de acurácia detalhados por classe, índices Kappa, índice de precisão global e Matrizes de confusão.

Os índices de acurácia detalhados são:

- *TP Rate* – Positivos verdadeiros – Instâncias corretamente classificadas de acordo com a classe dada
- *FP Rate* – Falsos Positivos – Instâncias classificadas de forma equivocada de acordo com a classe dada
- *Precision* – proporção de instâncias corretamente classificadas dividida pelo total de instâncias classificadas da classe. Quantidade de itens selecionados que são relevantes.
- *Recall* – proporção de instâncias classificadas da classe dada dividida pelo total atual naquela classe. Indica a proporção de positivos identificados corretamente.
- *F-Measure* – Mensuração combinada de *Precision* e *Recall* ($2 * Precision * Recall / (Precision + Recall)$) – Média harmônica entre os dois parâmetros.
- *MCC* – *Matthews Correlation Coefficient* – Considera os verdadeiros positivos (TP), verdadeiros negativos (TN), falsos positivos (FP) e falsos negativos (FN). Demonstra o desempenho do classificador de forma geral, considerando todas as entradas da matriz de confusão.
- *ROC Area* – *Received Operator Characteristic under the curve*. Aponta a proporcionalidade entre as amostras dadas, com base nos positivos verdadeiros e falsos. Valores > 0,8 apontam resultados consistentes.
- *PRC Area* – *Precision and Recall under the curve*. Indica também a proporcionalidade entre as amostras dadas, com base em *Precision* e *Recall*. Valores > 0,8 apontam resultados consistentes.

O índice Kappa descreve e testa o grau de concordância e precisão na classificação, utilizando todos os elementos da matriz de erros em seu cálculo (COHEN, 1960).

O índice de precisão global, expressa a porcentagem da área do mapa que foi corretamente classificada em comparação com o conjunto de dados de referência (conjunto de amostras) (STORY; CONGALTON, 1986).

As matrizes de confusão apresentam o desempenho do classificador, por classe, através dos valores reais obtidos das amostras em função dos valores preditos. Essa análise pode fornecer comparação mais eficientes do que apenas considerar o índice de exatidão global (JENSEN, 1986).

Uma análise temporal foi feita entre os dois meses, por meio do *plugin* MOLUSCE (*Modules for Land Use Change Evaluation*) no QGIS 2.18. Neste complemento, são dadas as porcentagens de mudanças entre as classes temáticas e é possível verificar a localização de cada uma delas.

Com a localização das mudanças na classe de vegetação arbórea, cruzou-se essas áreas com o cálculo de APP realizado para a base de dados do SISEMA. Dados de rede de drenagem da Bacia Do Rio Grande foram obtidos no SISEMA (2019) e as APP de calha e rio foram calculadas considerando que os rios da região tivessem menos de 10m de largura, portanto, uma APP de calha de rio de 30m (BRASIL, 2012).

Além disso, nos 4 pontos de ocorrências denunciados à Polícia Civil no mês de junho, foi realizada uma avaliação visual da mudança de uso e cobertura do solo, por meio do resultado obtido pelo MOLUSCE, juntamente com os dados de APP.

2.3. RESULTADOS E DISCUSSÃO

2.3.1. Segmentação

Os parâmetros de segmentação foram os mesmos para as duas imagens, sendo o parâmetro de escala = 30, forma = 0,1 e compacidade = 0,5. Na imagem de junho foram criados 126.651 objetos, enquanto na imagem de julho, 116.230 objetos. Amostras de 5 classes (vegetação arbórea, vegetação rasteira, cultivo, solo exposto e área construída), conforme as Figura 2.6 e Figura 2.7 abaixo.

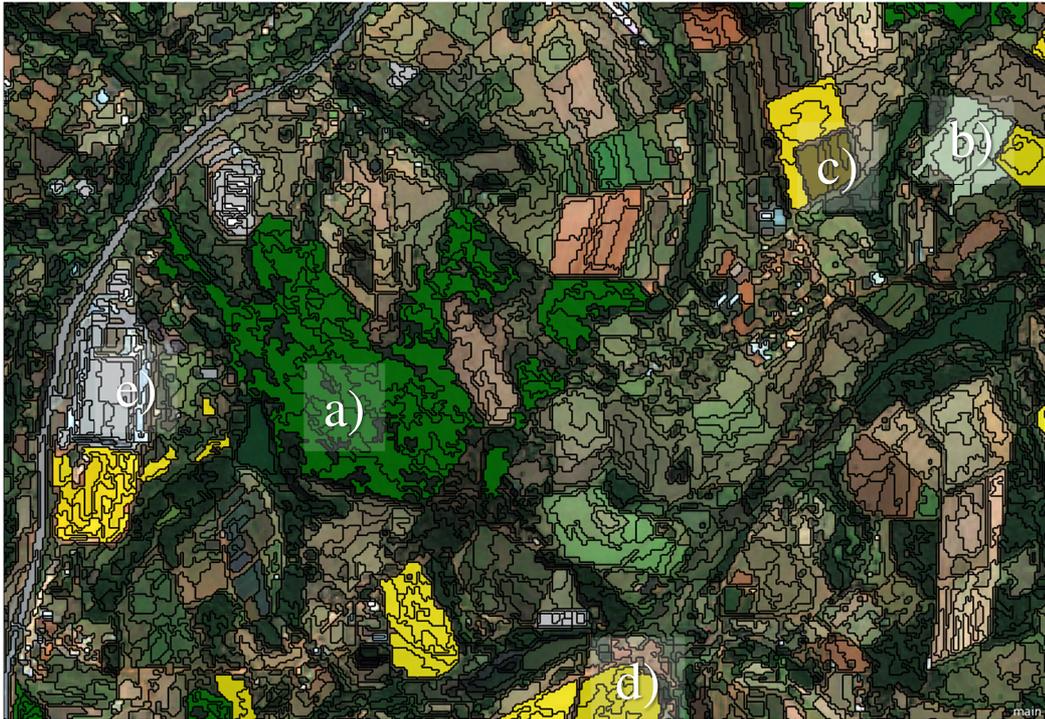


Figura 2.6 – Segmentação do mês de junho com exemplo de amostras: a) veg. arbórea; b) veg. rasteira; c) cultivo; d) Solo exposto; e) área construída.



Figura 2.7 - Segmentação do mês de julho.

2.3.2. Mineração de dados

O conjunto total de atributos foi minerado, pelo algoritmo J48, a fim de se verificar quais atributos seriam mais relevantes para a classificação. Dos 43 atributos selecionados na Seção 2.2.2.4, 36 atributos foram minerados pelo algoritmo J48 para a construção da árvore de decisão. Os atributos não selecionados foram: *Mean R*, *Mean difference R*, *Mean difference G*, *Mean difference B*, *Mean difference NIR*, *Brightness* e *Border index*.

2.3.3. Árvores de decisão

A árvore de decisão gerada no WEKA teve 97 folhas, tendo um tamanho da árvore de 193. O atributo do nó raiz, que possui maior importância para a árvore, foi o NDVI. Na Tabela 2.2 são apresentados os resultados.

Tabela 2.2 – Dados da exatidão global e índice Kappa da árvore de decisão

Algoritmo - Árvore de Decisão	Nº de atributos brutos	Nº de atributos selecionados	Índice Kappa	Exatidão Global
<i>J48</i>	43	36	0,9072	92,597%

O fluxograma da árvore está disponível no APÊNDICE VII – Fluxograma da árvore de decisão. Essa árvore foi escolhida para ser submetida à classificação temática.

2.3.4. Mapas temáticos

Nas Figura 2.8 e Figura 2.9 são apresentadas as imagens classificadas de acordo com a árvore de decisão.

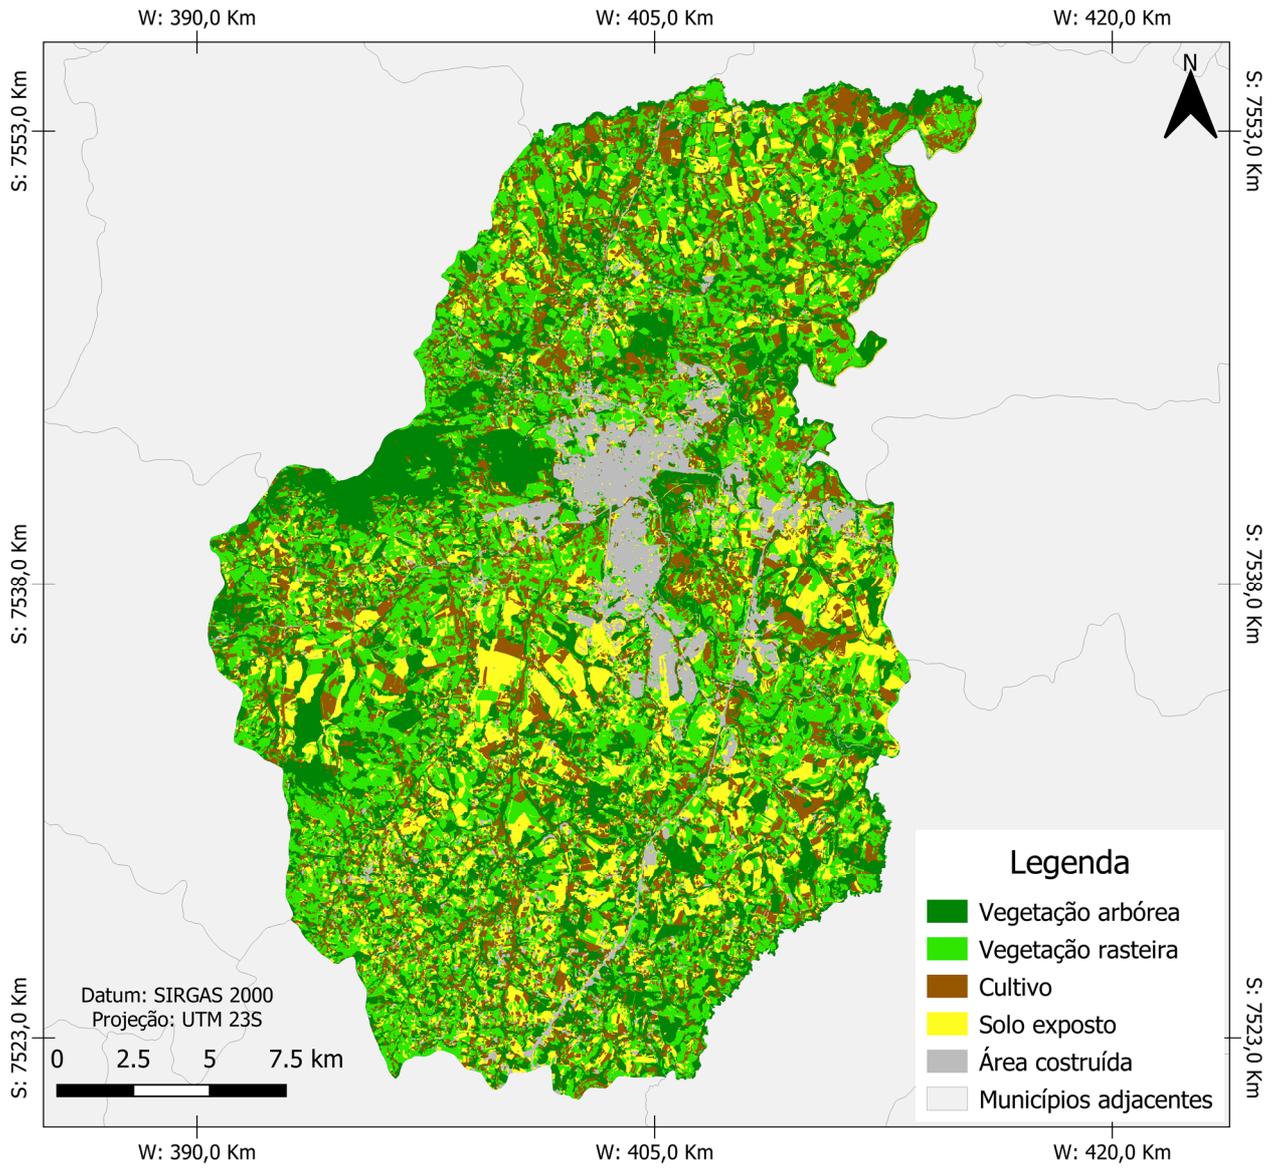


Figura 2.8 – Mapa da classificação temática para a imagem Sentinel-2 de junho/2018

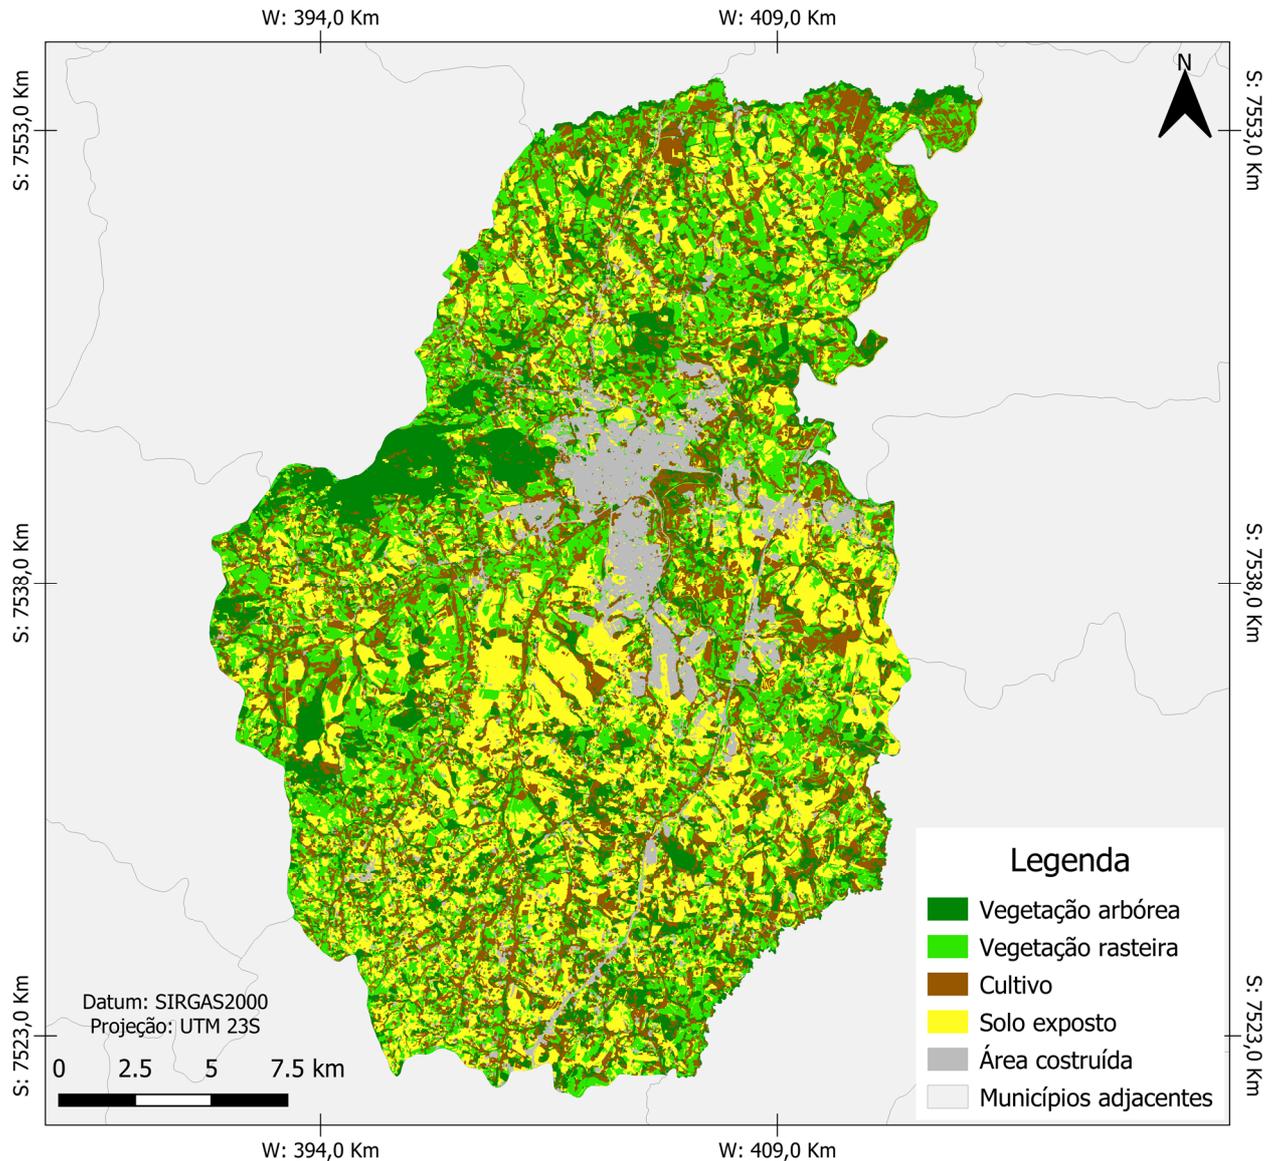


Figura 2.9 - Mapa da classificação temática para a imagem Sentinel-2 de julho/2018

Nas Tabela 2.3 e Tabela 2.4 são apresentadas as matrizes de confusão e a acurácia detalhada por classe para cada classificação temática das imagens.

Tabela 2.3 – Matriz de Confusão para as imagens Sentinel-2 de Pouso Alegre

Matriz Confusão - (Kappa = 0,9072)						Classes	
a	b	c	d	e			
645	75	23	2	18	763	a = Cultivo	
62	732	18	3	4	819	b = Veg. Rasteira	
21	17	782	16	5	841	c = Solo exposto	
4	3	15	982	1	1005	d = Área construída	
20	4	2	0	774	800	e = Veg. Arbórea	
752	831	840	1003	802	4228	Total	

Tabela 2.4 – Índices de acurácia por classe para as imagens Sentinel-2 de Pouso Alegre

Acurácia detalhada por classe								
TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Classes
0,845	0,031	0,858	0,845	0,851	0,819	0,920	0,771	Cultivo
0,894	0,029	0,881	0,894	0,887	0,860	0,944	0,817	Veg. Rasteira
0,930	0,017	0,931	0,930	0,930	0,913	0,958	0,864	Solo exposto
0,977	0,007	0,979	0,977	0,978	0,971	0,985	0,970	Área construída
0,968	0,008	0,965	0,968	0,966	0,958	0,980	0,939	Veg. Arbórea
0,926	0,018	0,926	0,926	0,926	0,908	0,959	0,877	Média ponderada

Pela observação das Tabelas acima, nota-se que o classificador está otimizado, uma vez que os ROC e PRC Area estão todos mais próximos de 1. O parâmetro *F-Measure*, que incorpora os de “Precision” e “Recall”, demonstra bom desempenho para todas as classes, principalmente para a classe de Veg. Arbórea, utilizada para identificar fragmentos de vegetação de APP. O MCC, que incorpora todas as entradas da matriz de confusão, aponta também um bom desempenho do classificador. As classes com maiores problemas de confusão na classificação foram a de Cultivo (PRC < 0,8 e MCC ~ 0,8) e a de Veg. Rasteira (PRC ~ 0,8 e MCC ~ 0,85), com aproximadamente 10% das amostras de Veg. Rasteira sendo classificadas erroneamente como Cultivo. A Veg. Arbórea teve baixos níveis de confusão, o menor nível de confusão dentre todas as classes, sendo o nível de confusão mais significativo com a classe de cultivo.

2.3.5. Análise de mudanças no uso do solo

As mudanças de uso do solo entre as duas imagens classificadas foram avaliadas para se obter a quantidade de vegetação arbórea que foi transformada em outras classes, ou seja, desmatada. A Tabela 2.5 apresenta as transformações totais (Δ) por classe calculadas pelo *plugin* MOLUSCE. A Figura 2.10 apresenta o perfil das áreas alteradas conforme seu tamanho. Foram encontradas 38.519 áreas de mudanças de uso do solo.

Tabela 2.5 – Transformações totais e em porcentagem por classe entre as imagens classificadas

Classes	jun/18	jul/18	Δ	jun/2018 [%]	jul/2018 [%]	Δ %
veg. Arbórea	139,46 km ²	88,92 km ²	-50,55 km ²	25,7083	16,3903	-9,3179
veg. Rasteira	168,49 km ²	135,07 km ²	-33,42 km ²	31,0587	24,8982	-6,1604
cultivo	107,10 km ²	125,40 km ²	18,31 km ²	19,7422	23,1165	3,3743
solo exposto	87,17 km ²	149,37 km ²	62,20 km ²	16,0683	27,5339	11,4656
área construída	40,27 km ²	43,73 km ²	3,46 km ²	7,4224	8,0609	0,6385

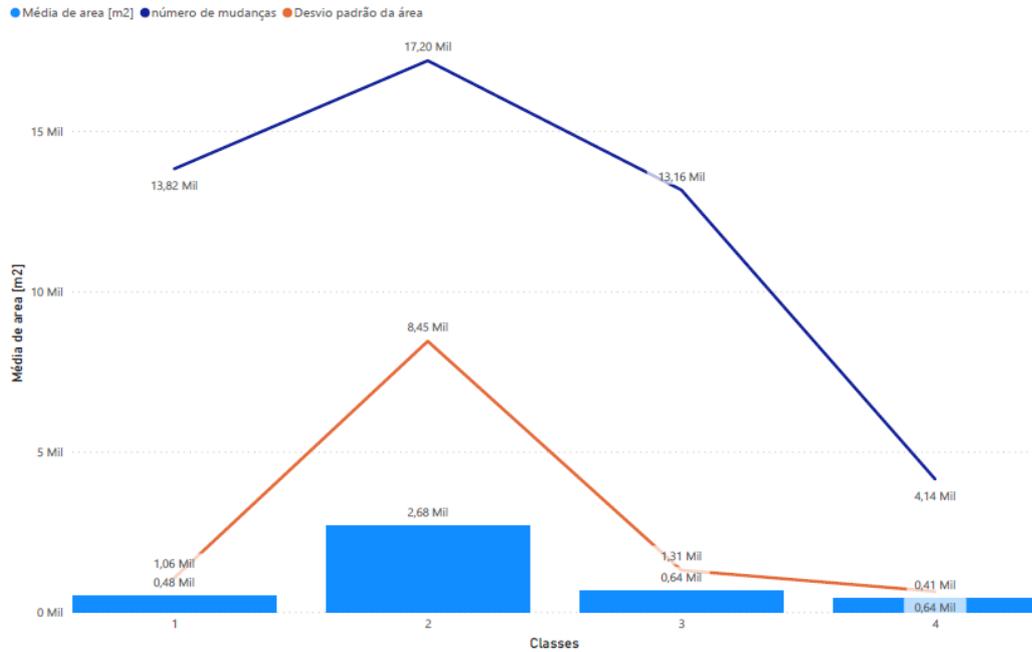


Figura 2.10 – Análise dos dados de mudança de uso do solo. Classe 1 = Veg. arbórea -> veg. rasteira; Classe 2 = Veg. arbórea -> cultivo; Classe 3 = Veg. arbórea -> solo exposto; Classe 4 = Veg. arbórea -> área construída.

Pela Figura 2.10 nota-se uma forte presença de mudanças de vegetação arbórea para cultivo (35,59% das áreas de mudanças), com áreas em média de 2600 m² aproximadamente (26 pixels). As outras mudanças de solo seguem um padrão semelhante. Outro ponto a se considerar é o alto desvio-padrão na classe 2, que indica uma alta variância no tamanho das áreas. Em apenas um mês de análise, espera-se um número menor de áreas de pequenas variações no uso do solo, em menor número do que foi encontrado para a classe 2 = Veg. arbórea -> cultivo.

Para provar estatisticamente que a média da classe 2 difere de todas as outras, utilizou-se do teste ANOVA (*Analysis of Variance*) no *software* Minitab, versão 19.2020.1 gratuita de teste. Apesar do ANOVA ser um teste paramétrico, aplicado em amostras que seguem uma distribuição (ex. normal), o Minitab permite que o teste seja aplicado se a amostra tiver de 2 a 9 grupos e cada um deles possuir mais de 15 amostras (MINITAB, 2019). No caso do conjunto de amostras deste trabalho, apesar da distribuição não ser normal (verificado pelo teste de Ryan-Joiner, similar ao conhecido teste de Shapiro-Wilk), todas as orientações são satisfeitas.

Os dados foram inseridos no Minitab e as análises estatísticas foram geradas e estão disponíveis no APÊNDICE VIII – Teste estatístico ANOVA com comparação emparelhada. O teste ANOVA foi executado para um fator. Com um nível de significância $\alpha = 0,05$, ou seja, um Intervalo de Confiança (IC) de 95%, a hipótese nula de que todas as médias são iguais foi

rejeitada, uma vez que o Valor-P $< \alpha$. Com a rejeição da hipótese nula, a hipótese alternativa foi aceita, que afirma que nem todas as médias são iguais.

Para análise de qual média difere das demais, executou-se o teste de comparações emparelhadas de Tukey e de Dunnett. O resultado agrupou a classe 2 no agrupamento A, enquanto todas outras classes foram destinadas a outros agrupamentos, conforme Tabela 2.6. O resultado dos testes simultâneos emparelhados pode ser verificado na Figura 2.11.

Tabela 2.6- Informações de Agrupamento Usando o Método de Tukey e 95% de Confiança.

classe	N	Média	Agrupamento
2	17196	2676,7	A
3	13162	643,8	B
4	13819	484,63	B
1	4144	414,7	B

Médias que não compartilham uma letra são significativamente diferentes.

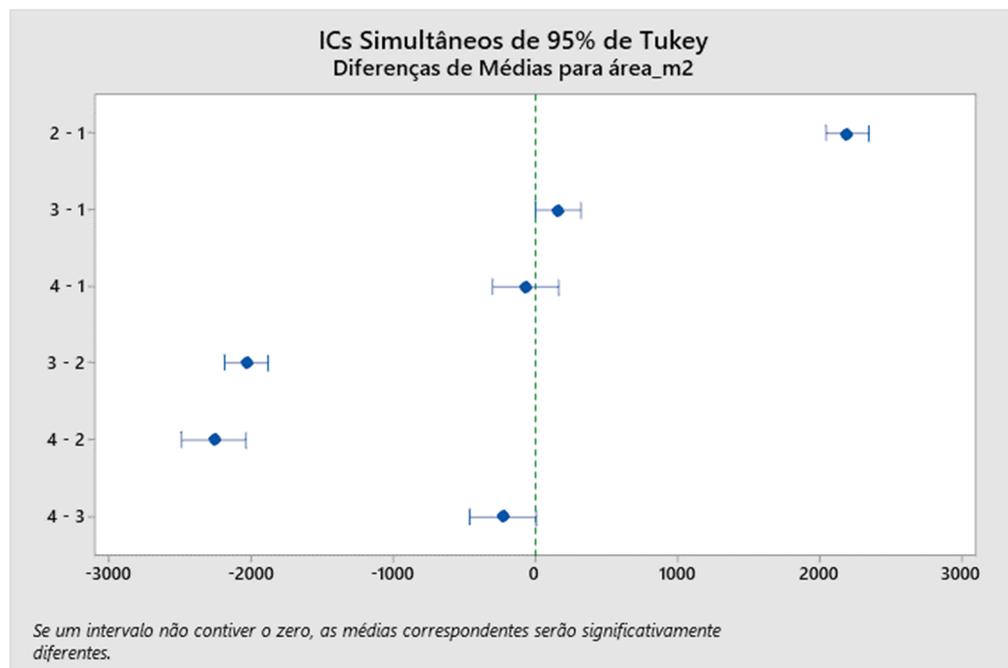


Figura 2.11 – Gráfico dos testes simultâneos de Games-Howell para a diferença de médias de áreas.

Pela Figura 2.11, observa-se as distâncias das comparações com relação à referência 0 (sem nenhuma diferença significativa). Todas as comparações emparelhadas com a classe 2 se distanciaram na referência 0, ou seja, diferem de forma significativa das outras classes. Pela Tabela 2.6, observa-se que a classe 2 foi agrupada de forma separada de todas as outras classes.

Com base na análise estatística das médias, no alto número de ocorrências da classe 2, e nos resultados anteriores dos indicadores de precisão e acurácia das classificações com relação à essa classe, evidencia-se a confusão entre as classes veg. arbórea e cultivo. Essa confusão se

reforça com o cálculo das mudanças de uso do solo. Várias áreas apontavam uma mudança do uso do solo de forma equivocada com grandes mudanças de área ($\Delta = 18,31 \text{ km}^2$), o que não seria possível no espaço temporal de um mês. Com isso, as mudanças de áreas classificadas de veg. arbórea para cultivo não foram consideradas nos resultados seguintes por não representarem uma mudança de uso do solo real.

A Tabela 2.7 abaixo apresenta a quantificação das variações na classe de Vegetação arbórea. A Figura 2.12 expõe o perfil de área das variações no uso de solo de vegetação arbórea encontradas.

As maiores mudanças de uso do solo são de vegetação arbórea transformada em vegetação rasteira com $6,70 \text{ km}^2$ (44,40% do total), seguidas pela mudança de arbórea para solo exposto, totalizando $8,47 \text{ km}^2$ (42,29% do total), e de arbórea para área construída, somando $1,71 \text{ km}^2$ (13,31% do total). Nota-se uma predominância de variações de $100 \text{ m}^2 - 200 \text{ m}^2$ (1-2 *pixel*) em todas as classes, totalizando 60,41% das variações de uso do solo encontradas. Variações maiores que 10 *pixels* ($> 1000 \text{ m}^2$), que são mais significativas e devem ser alvo de maiores investigações por parte da Polícia Civil, representam cerca de 12,47% do total, ou seja, $2,10 \text{ km}^2$.

Tabela 2.7 – Variações no uso do solo após análise estatística

Mudanças uso do solo	[km²]
veg. arbórea que se manteve	76,55
veg. arbórea -> veg. rasteira	6,70
veg. arbórea -> solo exposto	8,47
veg. arbórea -> área construída	1,71
Total de variação (Δ)	16,88

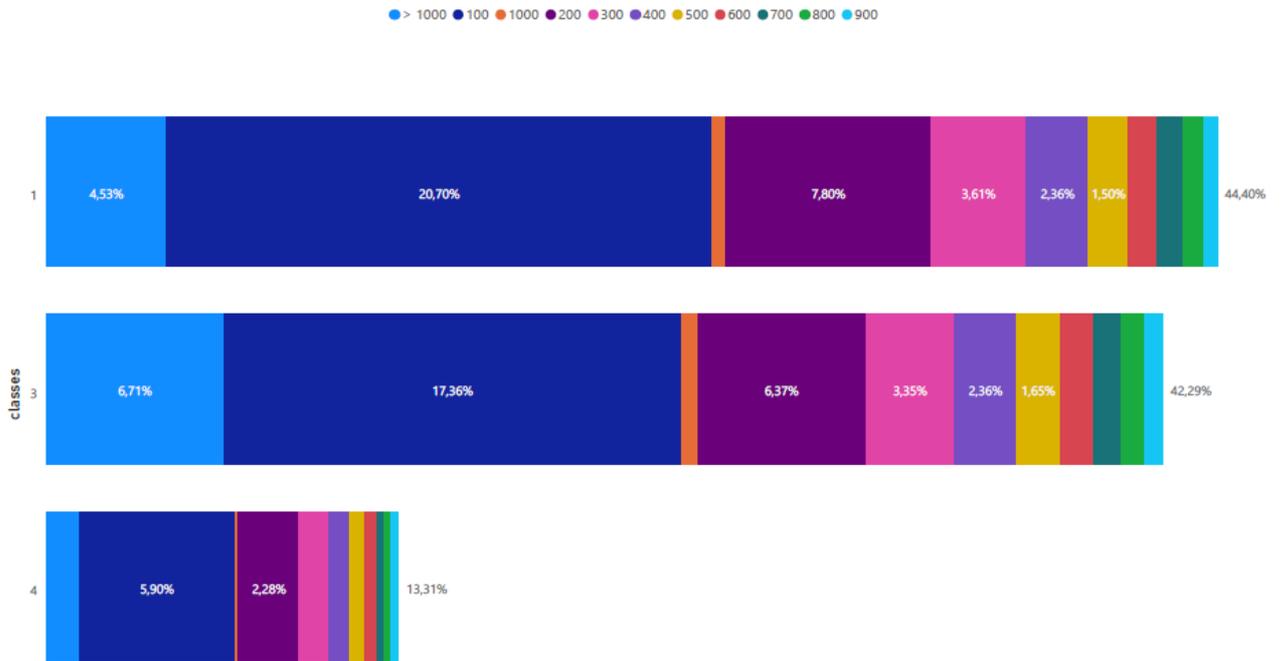


Figura 2.12 – Perfil das áreas de variação no uso do solo no município de Pouso Alegre em junho/2018. Classe 1 = Veg. arbórea -> veg. rasteira; Classe 3 = Veg. arbórea -> solo exposto; Classe 4 = Veg. arbórea -> área construída.

Os dados de mudança no uso do solo foram cruzados com as APP de calha de rio traçadas. A Figura 2.13 introduz o mapa de localização das áreas de vegetação arbórea alteradas em APP de calha de rio. Foram 3043 pontos de mudanças de uso do solo em APP, somando uma área de 0,74 km² de intervenções em APP.

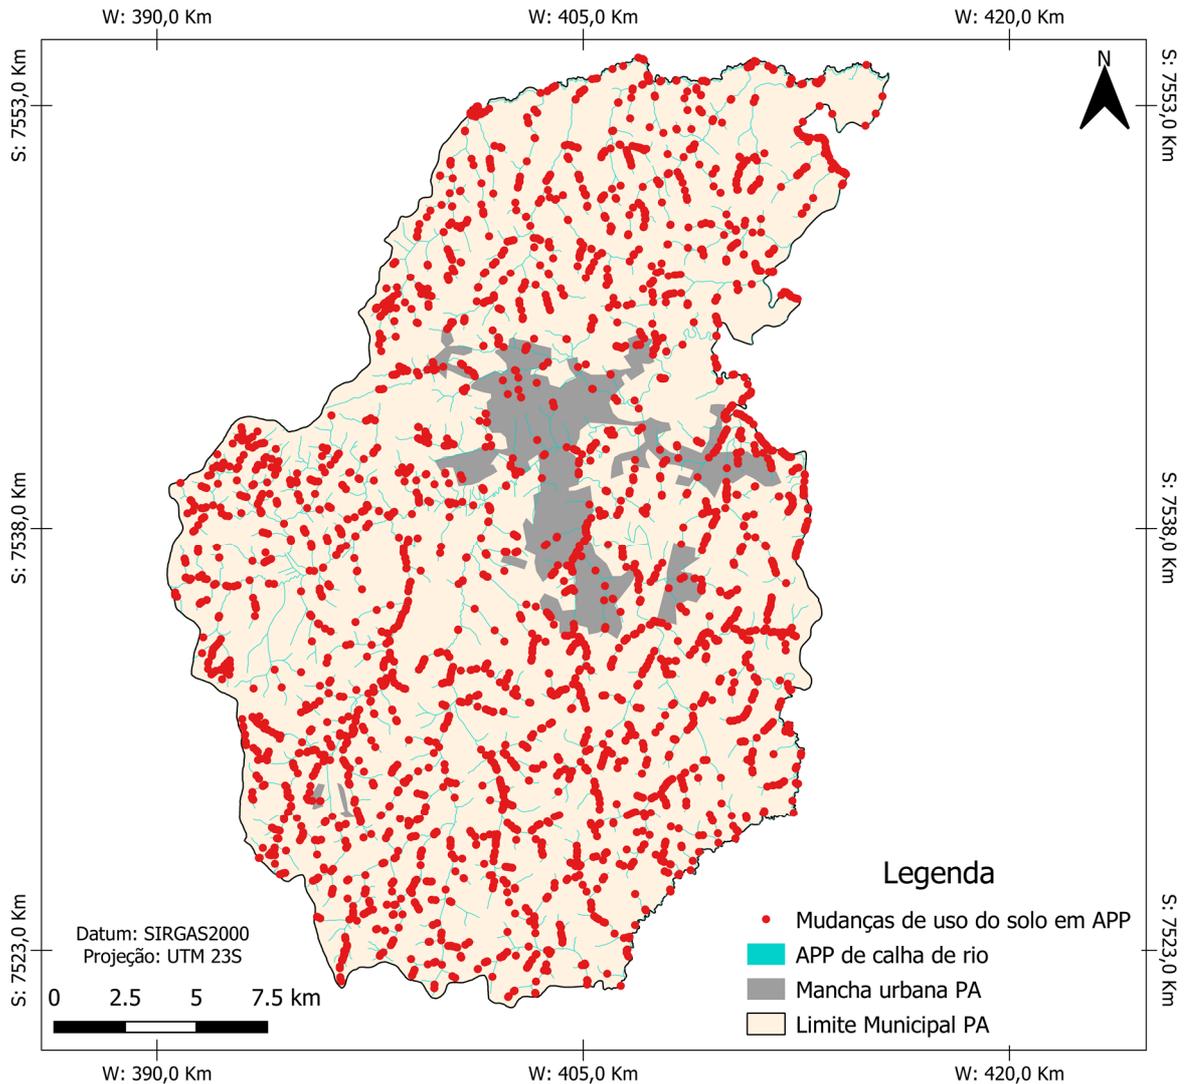


Figura 2.13 – Mapa de localização das áreas com mudança de uso no solo em APP de calha de rio no município de PA

O perfil das áreas de mudanças no uso do solo detectadas em APP de calha de rio é exposto na Figura 2.14. Percebe-se um padrão de distribuição das mudanças em uso do solo em APP parecido ao que foi diagnosticado para as mudanças de uso do solo no município, com a primeira posição da conversão de vegetação arbórea em vegetação rasteira (44,46%), seguida da conversão em solo exposto (40,91%) e da conversão em área construída (14,62%). O padrão dessas áreas de mudança no uso do solo em APP é na sua maioria de áreas pequenas (cerca de 78%), de até 300 m² (3 *pixels*). Variações de áreas muito pequenas podem ser explicadas pelas confusões do classificador. A atenção da fiscalização deve se voltar para áreas maiores, como por exemplo as áreas maiores de 1.000 m² que totalizam 138 pontos (cerca de 4,56%).

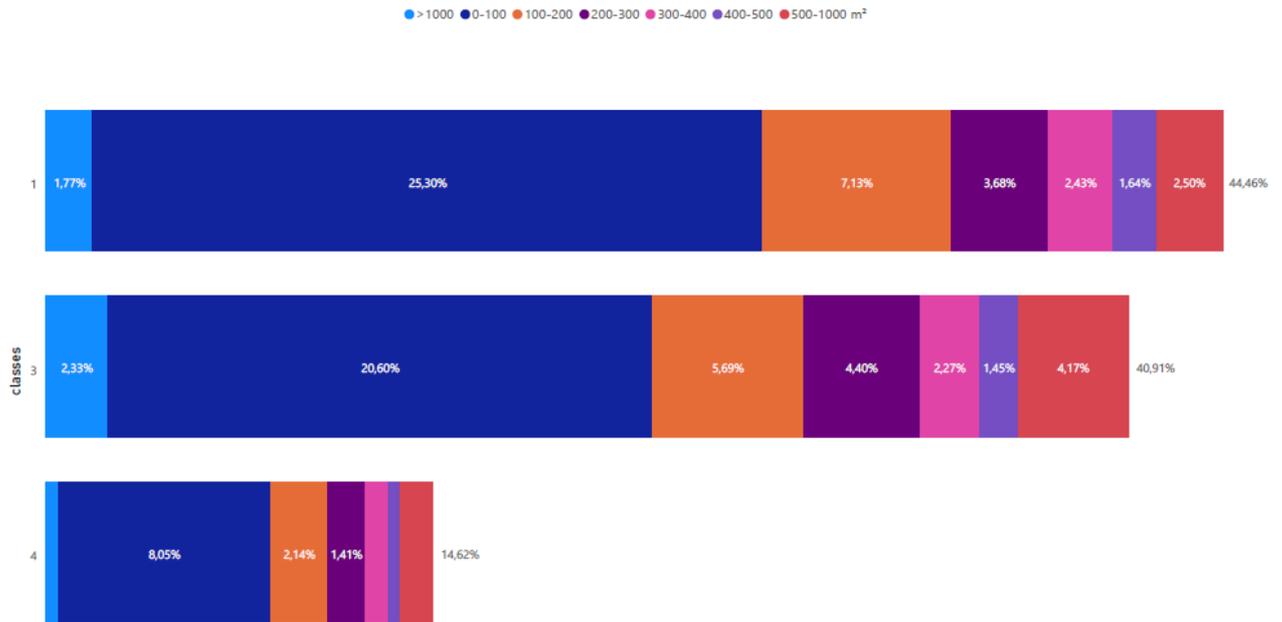


Figura 2.14 - Perfil das áreas de variação no uso do solo em APP no município de Pouso Alegre em junho/2018. Classe 1 = Veg. arbórea -> veg. rasteira; Classe 3 = Veg. arbórea -> solo exposto; Classe 4 = Veg. arbórea -> área construída.

Os pontos de ocorrências obtidos da Polícia Civil foram cruzados visualmente com os dados de mudança de uso do solo e com a base de dados da rede de drenagem e suas respectivas APP de calha de rio em busca de identificar áreas que sofreram intervenções antrópicas. As Figura 2.15, Figura 2.16, Figura 2.17 e Figura 2.18 apresentam detalhadamente as 4 ocorrências.

Nas aproximações dos pontos de ocorrência do mês de junho, observa-se que as ocorrências não são localizadas precisamente em uma APP. Além disso, há mudanças de uso do solo próximas, mas, novamente, não exatamente no lugar registrado da ocorrência. Na Figura 2.15, ocorrência do dia 25/06/18, foram localizadas mudanças de uso do solo próximas ao ponto registrado, porém sem nenhuma APP por perto; o mesmo ocorre para a ocorrência do dia 28/06/18, Figura 2.16. Nas duas ocorrências do dia 29/06/18, Figura 2.17 e Figura 2.18, ambas foram reportadas próximas à APP, contudo na primeira houve a presença de mudança de uso do solo próxima (Figura 2.17), enquanto na outra (Figura 2.18) as mudanças de uso do solo estão mais distantes.

Essa diferença na posição, pode ser oriunda do método de registro da ocorrência pelo perito da Polícia Civil, uma vez que as coordenadas são inseridas manualmente na hora da investigação e, muitas vezes, pode não representar a localização real da ocorrência. Outro fator pode ser a resolução espacial das imagens utilizadas na análise (10m), visto que uma imagem com melhor resolução espacial e detalhamento geraria resultados mais precisos. Diante das

condições da pesquisa, fontes de dados gratuitas tiveram que ser usadas e as imagens do Sentinel-2A foram as mais indicadas.

Contudo, mesmo com a imprecisão do registro da ocorrência e a limitação da resolução espacial disponível, as mudanças identificadas no uso do solo de vegetação arbórea, que envolvem APP, podem servir de orientação para uma melhor fiscalização por parte da Polícia Civil, visando uma gestão eficiente de recursos. Essa mesma metodologia aplicada em imagens de melhor resolução pode trazer melhores resultados.

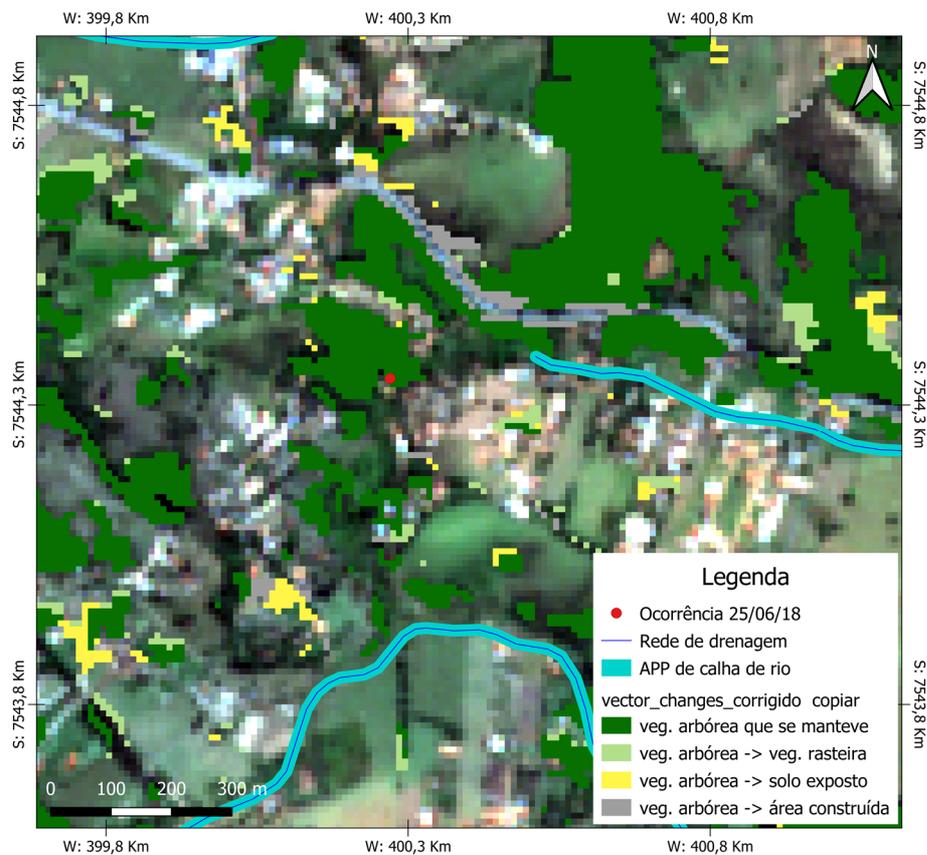


Figura 2.15 – Zoom nas proximidades da ocorrência de 25/06/18 em PA

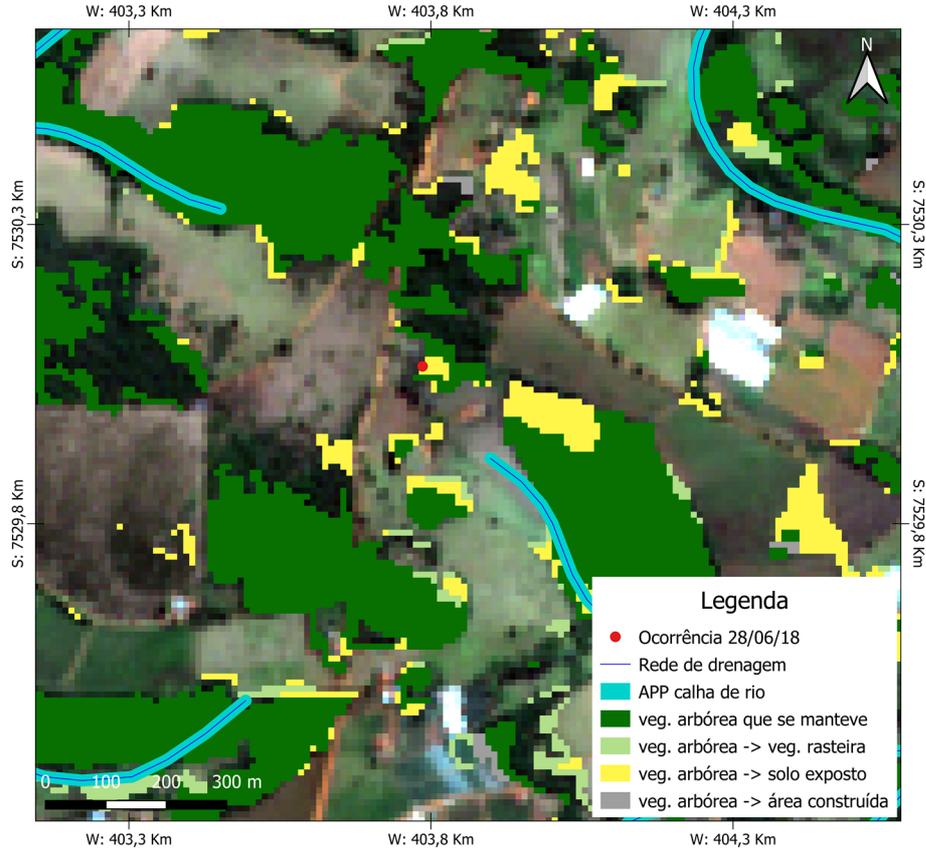


Figura 2.16 - Zoom nas proximidades da ocorrência de 28/06/18 em PA

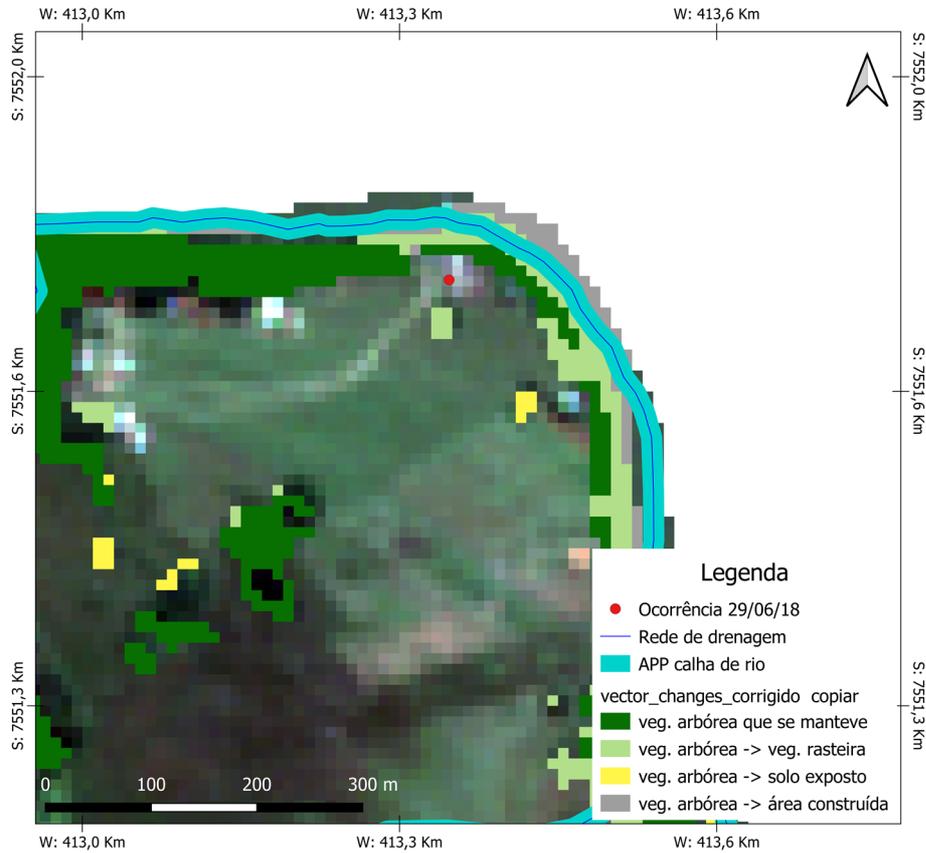


Figura 2.17 - Zoom nas proximidades da ocorrência de 29/06/18 em PA

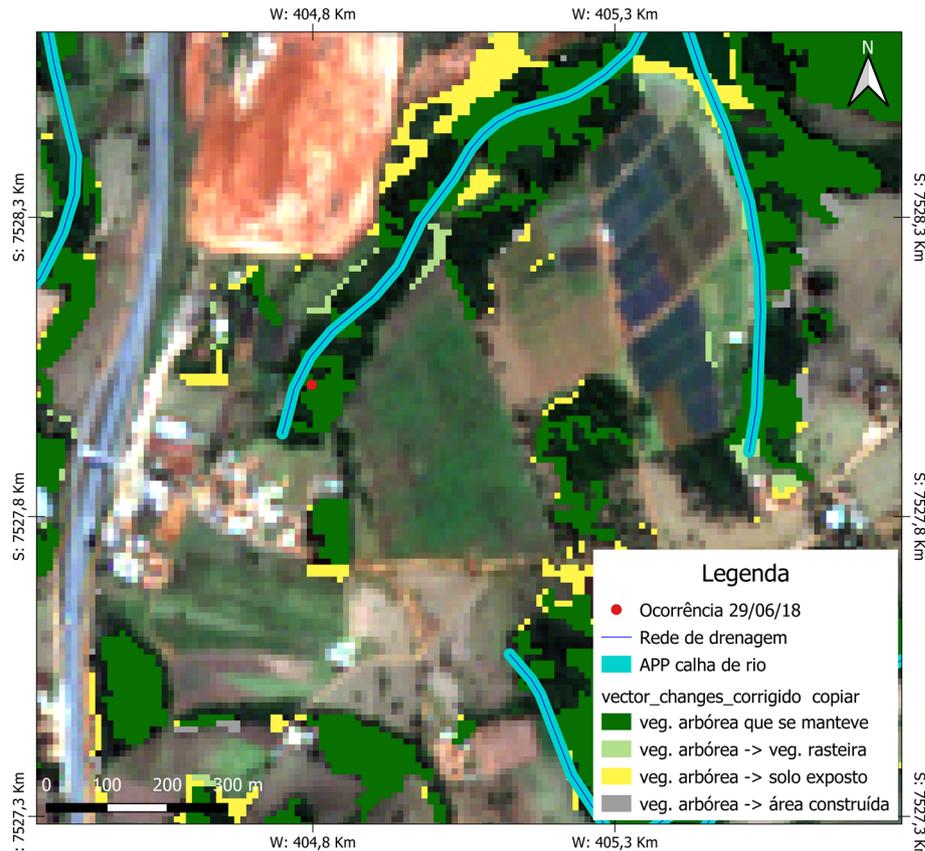


Figura 2.18 - Zoom nas proximidades da segunda ocorrência de 29/06/18 em PA

As pequenas variações de uso no solo e, conseqüentemente, de intervenções antrópicas podem ser resultantes das pequenas imprecisões na classificação, já que o modelo definido pela árvore de decisão não é perfeito. As grandes variações devem ser investigadas mais profundamente pela Polícia Civil, pois provavelmente representam uma mudança mais significativa no solo.

2.4. CONCLUSÕES

Diante da conjuntura de monitoramento limitado da Polícia Civil responsável pelas investigações ambientais, seja pela falta de efetivo ou pela gestão ineficaz de recursos, um monitoramento indireto para suporte à decisão se faz necessário. A metodologia proposta neste estudo, que foi aplicada na data em que um município demonstrou um aumento de denúncias de intervenção antrópica em APP, se mostrou positiva, uma vez que foi capaz de identificar com precisão satisfatória, de acordo com índices de precisão e acurácia, as áreas arbóreas que, juntamente com o cálculo da APP calha de rio, são utilizadas na investigação de intervenções antrópicas. Uma variação de 16,88 km² em áreas de vegetação arbórea foi detectada, sendo 3043 pontos de variação em APP de calha de rio que somam uma área de 0,74 m² ou 740.000 m².

Um padrão de mudanças de uso do solo com pequenas áreas de 1 *pixel* (100m²) foi observado, tanto para o município inteiro quanto apenas para as APP. Esse padrão pode ser explicado pelas confusões do classificador que, mesmo sendo bem preciso com Índice Kappa de 0,9072, *F-Measure* médios de 0,926, ROC e PRC próximos de 1, ainda possui uma pequena porcentagem de confusão entre as classes e entre as amostras de validação dadas. Além disso, houve uma confusão significativa de áreas de vegetação arbórea com a classe de cultivo, que foi desconsiderada dos cálculos. Para a gestão dos esforços e recursos da PC, as grandes variações devem ser investigadas mais profundamente, pois provavelmente representam uma mudança mais significativa no solo. Diante de todos os resultados observados, considera-se que os objetivos propostos foram cumpridos de forma satisfatória.

Espera-se que esse estudo sirva de embasamento para próximas análises na região do Sul de Minas e que os resultados delimitados auxiliem na melhoria da gestão de recursos financeiros e humanos da Polícia Civil, a fim de se fiscalizar as áreas de APP e, conseqüentemente, o bioma da Mata Atlântica.

REFERÊNCIAS BIBLIOGRÁFICAS

- BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 65, p. 2–16, 2010.
- BLASCHKE, T.; HAY, G. J.; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; FEITOSA, R. Q.; VAN DER MEER, F.; VAN DER WERFF, H.; VAN COILLIE, F.; TIEDE, D. Geographic object-based image analysis – towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, Amsterdam, v. 87, p. 180–191, 2014.
- BRASIL. Lei nº 12.561 de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa. **Diário Oficial da União**, Brasília, DF, 25 maio 2012.
- CASTRO, L. N.; FERRARI, D. G. **Introdução à mineração de dados**: conceitos básicos, algoritmos e aplicações. 1 ed. São Paulo: Editora Saraiva, 2016.
- CECCARELLI, T.; SMIRAGLIA, D.; BAJOCCHO, S.; RINALDO, S.; DE ANGELIS, A.; SALVATI, L.; PERINI, L. Land cover data from Landsat single-date imagery: an approach integrating pixel-based and object-based classifiers. **European Journal of Remote Sensing**, Oxfordshire, v. 46, p. 699- 717, 2013.
- CLEMENTE, C. M. S.; ESPÍRITO-SANTO, M. M. D.; LEITE, M. E. Estimates of deforestation avoided by protected areas: a case study in Brazilian tropical dry forests and Cerrado. **Landscape Research**, Oxfordshire, v. 45, n. 4, p. 470-483, 2020.
- COHEN, J. A Coefficient of Agreement for Nominal Scales. **Educational and Psychological Measurement**, New York, v. 10, n. 1, p. 37-46, 1960.
- COSTA, D. P.; VENDRUSCOLO, J.; ROSA, D. M.; MENDES, D. M.; CAVALHEIRO, W. C. S.; RODRIGUES, A. A. M. Morfometria e dinâmica de desmatamento da microbacia Canaã, Amazônia, Brasil/Morphometry and deforestation dynamics of Canaã microbasin, Amazonia, Brazil. **Brazilian Journal of Development**, São José dos Pinhais, v. 5, n. 12, p. 30754-30772, 2019.
- ESA. **Copernicus Open Access Hub**, 2020. Página Inicial. Disponível em: <https://scihub.copernicus.eu/dhus/#/home>. Acesso em: 15 dez. 2020.
- FILHO, A. S. L. S.; MENSAH, J. H. R.; BATTISTON, K. M.; BARROS, M. S.; SANTOS, I. F. S. Dimensionamento de um reator uasb para tratamento de efluentes domésticos e recuperação do biogás para produção energética: um estudo de caso em Pouso Alegre (MG). **Revista Brasileira de Energias Renováveis**, Curitiba, v. 7, n. 1, p. 77-94, 2018.
- GRIFFITH, D. C.; HAY, G. J. Integrating GEOBIA, Machine Learning, and Volunteered Geographic Information to Map Vegetation over Rooftops. **International Journal of Geo-Information**, Basel, v. 7, n. 12, p. 1-25, 2018.
- IBGE. **Cidades**, 2017. Página Inicial. Disponível em: cidades.ibge.gov.br. Acesso em: 20 jul. 2020.
- JENSEN, J. R. **Introductory digital image processing**. Englewood Cliffs: Prentice - Hall, 1986.

LEÃO, T. C.; FONSECA, C. R.; PERES, C. A.; TABARELLI, M. Predicting extinction risk of Brazilian Atlantic Forest angiosperms. **Conservation Biology**, Hoboken, v. 28, n. 5, p. 1349-1359, 2014.

MACHALA, M.; ZEJDOVÁ, L. Forest mapping through object-based image analysis of multispectral and LiDAR aerial data. **European Journal of Remote Sensing**, Oxfordshire, v. 47, n. 1, p. 117-131, 2014.

MEDEIROS, A. R. C.; ARAÚJO, Y. B.; VIANNA, R. P. T.; MORAES, R. M. Modelo de suporte à decisão aplicado à identificação de indivíduos não aderentes ao tratamento anti-hipertensivo. **Saúde Debate**, Rio de Janeiro, v. 38, n. 100, p. 104-118, 2014.

MINITAB. **Como escolher entre um teste não-paramétrico e um teste paramétrico**, 2019. Blog da Minitab. Disponível em: <https://blog.minitab.com/pt/como-escolher-entre-um-teste-nao-parametrico-e-um-teste-parametrico#:~:text=O%20fato%20de%20voc%C3%AA%20poder,mediana%20e%2050%25%20est%C3%A3o%20abaixo>. Acesso em: 01 mar. 2021.

MOLNAR, C. **Interpretable Machine Learning: A Guide for Making Black Box Models Interpretable**. 1 ed. Victoria: Leanpub, 2020.

MYINT, S. W.; GOBER, P.; BRAZEL, A.; GROSSMAN-CLARKE, S.; WENG, Q. Pixel-a-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. **Remote Sensing of Environment**, Amsterdam, v. 115, n. 5, p. 1145-1161, 2011.

PORANGABA, G. F. O.; AMORIM, M. C. D. C. T. Geotecnologias Aplicadas à Análise de Ilhas de Calor de Superfície em Cidades do Interior do Estado de São Paulo. **Revista Brasileira de Geografia Física**, Recife, v. 12, n. 06, p. 2041-2050, 2019.

QUINLAN, J. R. **C4.5: programs for machine learning**. San Mateo: Morgan Kaufmann Publishers, 1993, 300p.

RAIMUNDO, D. R.; PEDREIRA, J. R. P.; SOUSA, L. C.; CÓRDOVA, M. E. H.; MIRANDA, R. T.; CAÑOTE, S. J. B. Estudo da viabilidade econômica e da produção energética do biogás gerado no tratamento de efluentes, aplicados à cidade de Pouso Alegre- MG. **Revista Brasileira de Energias Renováveis**, v.6, n. 5, p. 995-1016, 2017.

RAMOS, M. P.; NÓBREGA, R. A. A. Geotecnologias em perícias ambientais: aplicabilidade para estudos em represas de abastecimento e áreas protegidas. **Revista Ibero-Americana de Ciências Ambientais**, Aracaju, v. 11, n. 3, p. 469-484, 2020.

RAMYA, M. C.; LOKESH, V.; MANJUNATH, T. N.; RAVINDRA, S. H. A Predictive Model Construction for Mulberry Crop Productivity. **Procedia Computer Science**, Amsterdam, v. 45, p. 156-165, 2015.

RIBEIRO, G. V. B. A origem histórica do conceito de Área de Preservação Permanente no Brasil. **Revista Thema**, Pelotas, v. 8, n. 1, p. 1-13, 2011.

SÁNCHEZ, L. E. **Avaliação de impacto ambiental**. São Paulo: Oficina de Textos, 2013.

SATO, L. Y.; SHIMABUKURO, Y. E.; KUPLICH, T. M.; GOMES, V. C. F. Análise comparativa de algoritmos de árvore de decisão do sistema WEKA para classificação do uso e cobertura da terra. *In: Simpósio Brasileiro de Sensoriamento Remoto*, 16., 2013, Foz do Iguaçu.

Anais... São José dos Campos: INPE. p. 2353-2360. Disponível em: <http://marte2.sid.inpe.br/col/dpi.inpe.br/marte2/2013/05.28.23.55.20/doc/p0734.pdf>. Acesso em: 18 out. 2020.

SOS MATA ATLÂNTICA. **Atlas dos Remanescentes Florestais da Mata Atlântica Período 2018-2019**. São Paulo: Fundação SOS Mata Atlântica, 2020. Disponível em: https://www.sosma.org.br/wp-content/uploads/2020/06/2020_Atlas_Mata_Atlantica_2018-2019_relatorio_tecnico_final-1.pdf Acesso em: 23 jul. 2020.

SOUZA, U. D. V.; KUX, H. J. H. Geobias e mineração de dados na classificação da cobertura do solo urbano em São Luís (MA) com imagens worldview-2 e o sistema INTERIMAGE. **Revista Brasileira de Cartografia**, Rio de Janeiro, v. 66, n. 3, p.433-450, 2014.

STORY, M.; CONGALTON, R. G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and Remote Sensing**, Maryland, v. 52, n. 3, p. 397-399, 1986.

VIEIRA, E. M. A.; NEVES, N. T. A. T.; OLIVEIRA, A. C. C.; MORAES, R. M.; NASCIMENTO, J. A. Avaliação da performance do algoritmo J48 para construção de modelos baseados em árvores de decisão. **Revista Brasileira de Computação Aplicada**, Passo Fundo, v. 10, n. 2, p. 80-90, 2018.

ZHENG, L. Parameter Optimization in Multi-scale Segmentation of High Resolution Remotely Sensed Image and Its Application in Object-oriented Classification. *In: International Conference On Environmental Engineering And Remote Sensing*, 19., 2015, Phuket. **Proceedings...** France: Atlantis Press, 2015. p. 84-90. Disponível em: <https://www.atlantispress.com/proceedings/eers-15/25839153>. Acesso em: 15 out. 2020.

CONSIDERAÇÕES FINAIS

A região do Sul de Minas Gerais está inserida no bioma da Mata Atlântica que sofreu uma grande perda de vegetação nativa ao longo dos anos. Mesmo com os esforços do governo em criar uma legislação ambiental e ferramentas, como as APP, que visam proteger a vegetação restante, relatórios apontam para o desmatamento desse bioma em toda sua extensão (SOS MATA ATLÂNTICA, 2019).

Dados da Polícia Civil de MG apontam para uma redução dos casos de intervenções antrópicas em APP, assim como a análise de tendência executada para esses dados, contudo o mapeamento de intervenções em APP com o uso da GEOBIA proposto por essa dissertação constatou que houve um aumento nos registros. Em pelo menos um mês, 138 áreas de intervenções antrópicas maiores de 1.000 m² foram identificadas. A precisão e acurácia dos resultados encontrados apontam para uma apuração satisfatória, com índices de Kappa de 0,9072, *F-Measure* médios de 0,926, ROC e PRC próximos de 1 e uma matriz de confusão com apenas uma classe (cultivo) com erros significativos. Essa classe foi excluída dos resultados posteriores.

A divergência encontrada entre os dados obtidos da PC e os resultados encontrados nesse estudo é reflexo, em sua maioria, da falta de material humano na fiscalização ao desmatamento, uma vez que a Polícia trabalha apenas com a urgência das denúncias feitas e não com o planejamento e prevenção. Um combate preventivo se faz necessário para a preservação da Mata Atlântica. Espera-se que esse estudo sirva de subsídio ao planejamento do combate ao desmatamento mais eficiente.

Em suma, a metodologia foi suficiente para o cumprimento dos objetivos específicos e, conseqüentemente, do objetivo geral de avaliar o potencial da classificação baseada a objetos na identificação e mapeamento de intervenções antrópicas em Áreas de Preservação Permanente. Com a aplicação dessa metodologia em diversos meses para diversos municípios, além da utilização de imagens com melhor resolução espacial, seria possível reforçar essa tendência de aumento para o 17º Departamento da Polícia Civil.

Ademais, considera-se que esse estudo contribuiu com a literatura, que até então não obtinha um estudo das ocorrências da PC relacionadas a intervenções em APP, e com a transmissão de conhecimento à sociedade.

REFERÊNCIAS BIBLIOGRÁFICAS GERAIS

AMARSAIKHAN, D.; BLOTEVOGEL, H. H.; VAN GENDEREN, J. L.; GANZORIG, M.; GANTUYA, R.; NERGUI, B. Fusing high resolution TerraSAR and Quickbird images for urban land cover study in Mongolia. **International Journal of Image and Data Fusion**, Oxfordshire, v. 1, n. 1, p. 83–97, 2010.

AMARSAIKHAN, D.; GANZORIG, M.; SAANDAR, M.; BLOTEVOGEL, H. H.; EGSHIGLEN, E.; GANTUYA, R.; NERGUI, B.; ENKHJARGAL, D. Comparison of multisource image fusion methods and land cover classification. **International Journal of Remote Sensing**, Oxfordshire, v. 33, n. 8, p. 2532–2550, 2012.

BRASIL. Lei nº 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa. **Diário Oficial da União**: seção 1, Brasília, 28 maio 2012.

CASTRO, F.A.T. Juventude rural e as contribuições do projeto transformar de capacitação de jovens rurais no Sul de Minas (2006-2013). **Em Extensão**, Uberlândia, v. 15, n. 2, p. 9-40, 2016.

CHAICHI, N.; DAIM, T. U. Landscape Analysis: Connected Lighting System. *In*: DAIM T. U.; CHAN L.; ESTEP J. (eds) **Infrastructure and Technology Management**. Innovation, Technology, and Knowledge Management. Cham: Springer, 2018. p. 45-65.

COUTINHO, L. M.; ZANETTI, S. S.; CECÍLIO, R. A.; DE OLIVEIRA GARCIA, G.; XAVIER, A. C. Usos da Terra e Áreas de Preservação Permanente (APP) na Bacia do Rio da Prata, Castelo-ES. **Floresta e Ambiente**, Rio de Janeiro, v. 20, n. 4, p. 425-434, 2013.

ENDERLE, D.; WEIH, R. C. Integrating supervised and unsupervised classification methods to develop a more accurate land cover classification. **Journal of Arkansas Academy of Science**, Fayetteville, v. 59, p. 65–73, 2005.

GASS, S. L. B.; VERDUM, R.; CORBONNOIS, J.; LAURENT, F. Áreas de preservação permanente (APPs) no Brasil e na França. **Revista Franco-Brasileira de Geografia**, Paris, v. 27, 2016.

IBGE. **Censo agropecuário 2017**. Rio de Janeiro: IBGE, 2019. Disponível em: https://biblioteca.ibge.gov.br/visualizacao/periodicos/3096/agro_2017_resultados_definitivos.pdf. Acesso em: 15 jun. 2020.

INPE. Coordenação geral de observação da terra. **Programa de monitoramento da Amazônia e demais biomas**. São José dos Campos: INPE, 2019. Disponível em: http://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/legal_amazon/rates. Acesso em: 20 jun. 2020.

LIU, D.; XIA, F. Assessing object-based classification: advantages and limitations. **Remote Sensing Letters**, Oxfordshire, v. 1, n. 4, p. 187–194, 2010.

MAKINDE, E. O.; SALAMI, A. T.; OLALEYE, J.B.; OKEWUSI, O. C. Object based and pixel based classification using Rapideye satellite imagery of Eti-Osa, Lagos, Nigeria. **Geoinformatics FCE CTU**, Prague, v. 15, n. 2, p. 59–70, 2016.

MARTINS, M. R.; REZENDE, M. L. Uso da integração lavoura-pecuária-floresta e proteção de áreas de preservação permanente em propriedades familiares. **Em Extensão**, Uberlândia, v. 19, n. 1, p. 98-105, 2020.

MINAS GERAIS. **Lei nº 20.992 de 16 de outubro de 2013**. Dispõe sobre as políticas florestal e de proteção à biodiversidade no Estado. Belo Horizonte: Assembleia Legislativa do Estado de Minas Gerais, 2013.

MMA – MINISTÉRIO DO MEIO AMBIENTE. **Áreas de Preservação Permanente e Unidades de Conservação & Áreas de Risco. O que uma coisa tem a ver com a outra?** Relatório de Inspeção da área atingida pela tragédia das chuvas na Região Serrana do Rio de Janeiro. Brasília: MMA, 2011.

MOSKAL, L. M.; DUNBAR, M. D.; JAKUBAUSKAS, M. E. Visualizing the forest: A forest inventory characterization in the yellowstone national park based on geostatistical models. *In*: WIDACKI, W.; BYTNEROWICZ, A.; RIEBAU, A. (eds.). **A Message from the Tatras: Geographical Information Systems & Remote Sensing in Mountain Environmental Research**. Kraków: Jagiellonian University Press, 2004. p. 219-232.

NYAMJARGAL, E.; AMARSAIKHAN, D.; MUNKH-ERDENE, A.; BATTSENGEL, V.; BOLORCHULUUN, C. Object-based classification of mixed forest types in Mongolia. **Geocarto International**, Oxfordshire, p. 1-12, 2019.

O’SULLIVAN, D.; BERGMANN, L.; THATCHER, J. E. Spatiality, Maps, and Mathematics in Critical Human Geography: Toward a Repetition with Difference. **The Professional Geographer**, Oxfordshire, v. 70, n. 1, p. 129–139, 2018.

PONDORFER, A. The perception of climate change: comparative evidence from the small-island societies of Bougainville and Palawan. **Environmental Development**, Amsterdam, v. 30, p. 21–34, 2019.

SILVA, D. D. E.; FELIZMINO, F. T. A.; OLIVEIRA, M. G. Avaliação da degradação ambiental a partir da prática da cultura do feijão no Município de Tavares-PB. **Holos**, Natal, v. 31, n. 8, p. 148-165, 2015.

SILVA, H. R. O.; GUIMARÃES, S. C. P.; OLIVEIRA, L. B. O uso do geoprocessamento na espacialização e avaliação das áreas de preservação permanente: Cidade de Porto Velho-RO. **Revista Franco-Brasileira de Geografia**, Paris, v. 30, 2017.

SOS MATA ATLÂNTICA. **Atlas dos Remanescentes Florestais da Mata Atlântica**. São Paulo: Fundação SOS Mata Atlântica, 2019. Disponível em: <https://www.sosma.org.br/wp-content/uploads/2019/10/Atlas-mata-atlanticaDIGITAL.pdf>. Acesso em: 30 jan. de 2020.

TEIXEIRA, M. B.; CAMARGO, P. L. T.; MARTINS JUNIOR, P. P. 2018. Uso das Imagens de sensores remotos para análise crítica da degradação do Cerrado no Alto Médio São Francisco-Minas Gerais. **Anuário do Instituto de Geociências**, Rio de Janeiro, v.14, n.1, p.245-254, 2018.

TREVISAN, D. P.; BISPO, P. C.; ALMEIDA, D.; IMANI, M.; BALZTER, H.; MOSCHINI, L. E. Environmental vulnerability index: An evaluation of the water and the vegetation quality in Brazilian Savanna and Seasonal Forest Biome. **Ecological indicators**, Amsterdam, v. 112, p. 106163, 2020.

TRIDAPALLI, J. P.; BORINELLI, B.; CAMPOS, M. F. S. S.; CASTRO C. Análise dos gastos ambientais no setor público brasileiro: características e propostas alternativas. **Revista de Gestão Social e Ambiental**, São Paulo, v. 2, n. 5, p. 79-95, 2011.

WEIH, R. C.; RIGGAN, N. D. Object-based classification vs. pixel-based classification: comparative importance of multi-resolution imagery. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Amsterdam, v. 38, 2012.

APÊNDICE I – Testes de tendência 1ª regional

Método

Tipo de modelo	Modelo de Tendência Quadrático
Dados	ocorrencias
Tamanho	9
NFaltantes	0

Equação de Tendência Ajustada

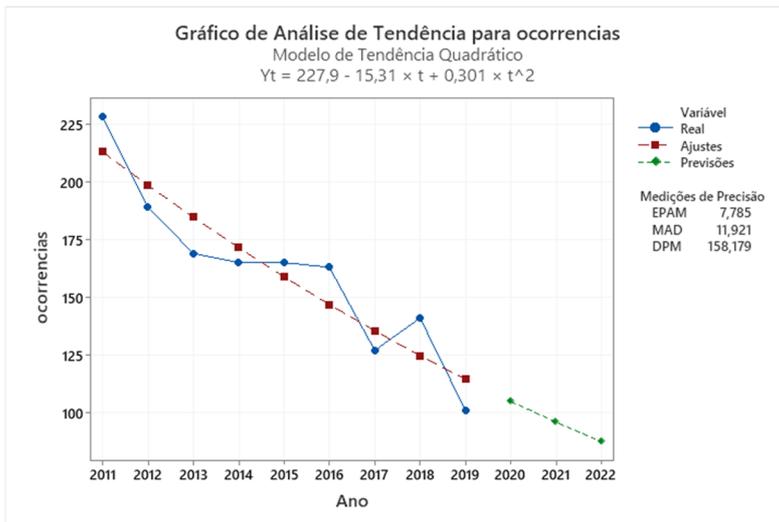
$$Y_t = 227,9 - 15,31 \times t + 0,301 \times t^2$$

Medições de Precisão

EPAM	7,785
MAD	11,921
DPM	158,179

Previsões

Período	Previsão
2020	104,905
2021	95,914
2022	87,526



Método

Tipo de modelo	Modelo de Tendência de Curva S
Dados	ocorrencias
Tamanho	9
NFaltantes	0

Equação de Tendência Ajustada

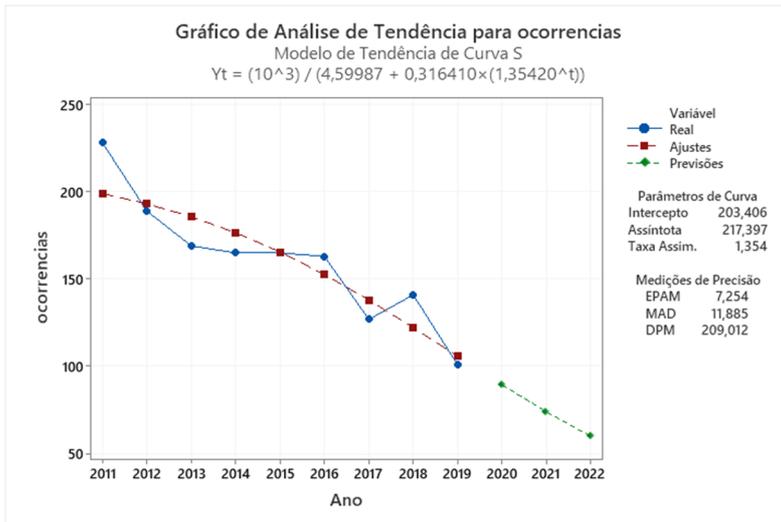
$$Y_t = (10^3) / (4,59987 + 0,316410 \times (1,35420^t))$$

Medições de Precisão

EPAM	7,254
MAD	11,885
DPM	209,012

Previsões

Período	Previsão
2020	89,5840
2021	74,1439
2022	60,1133



Método

Tipo de modelo Modelo de Tendência Linear
 Dados ocorrências
 Tamanho 9
 NFaltantes 0

Equação de Tendência Ajustada

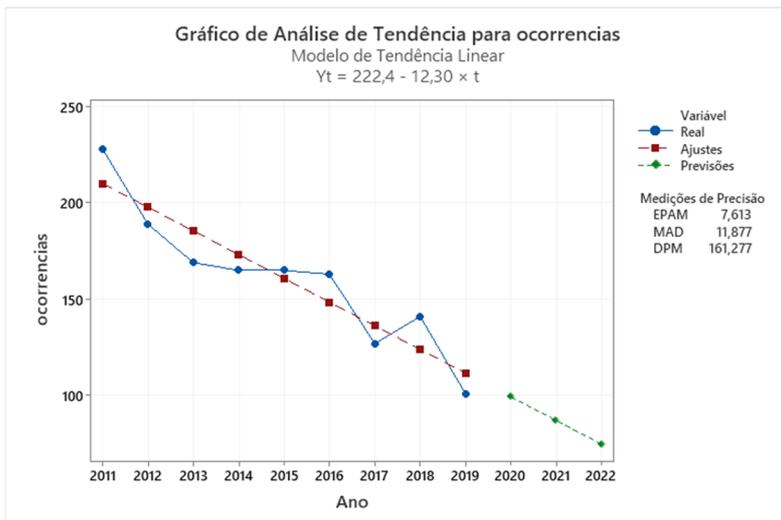
$Y_t = 222,4 - 12,30 \times t$

Medições de Precisão

EPAM 7,613
 MAD 11,877
 DPM 161,277

Previsões

Período	Previsão
2020	99,3889
2021	87,0889
2022	74,7889



APÊNDICE II – Testes de tendência 2ª regional

Método

Tipo de modelo	Modelo de Tendência Quadrático
Dados	ocorrença
Tamanho	9
NFaltantes	0

Equação de Tendência Ajustada

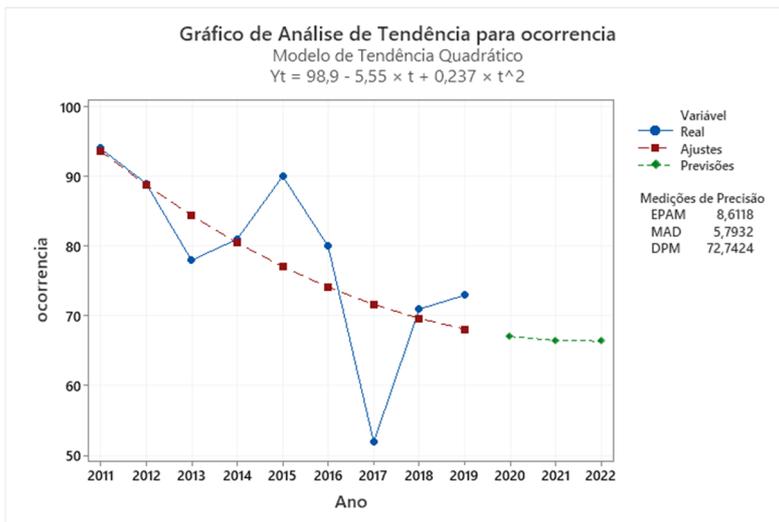
$$Y_t = 98,9 - 5,55 \times t + 0,237 \times t^2$$

Medições de Precisão

EPAM	8,6118
MAD	5,7932
DPM	72,7424

Previsões

Período	Previsão
2020	67,0952
2021	66,5190
2022	66,4169



Método

Tipo de modelo	Modelo de Tendência de Curva S
Dados	ocorrença
Tamanho	9
NFaltantes	0

Equação de Tendência Ajustada

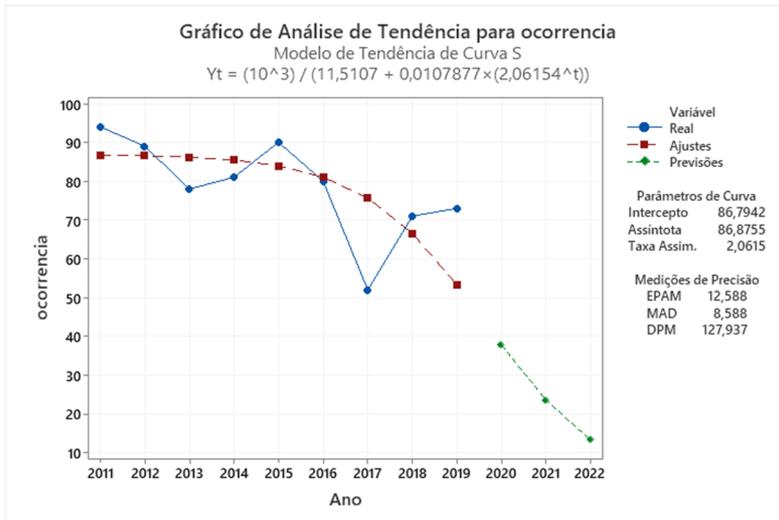
$$Y_t = (10^3) / (11,5107 + 0,0107877 \times (2,06154^t))$$

Medições de Precisão

EPAM	12,588
MAD	8,588
DPM	127,937

Previsões

Período	Previsão
2020	37,7819
2021	23,6155
2022	13,3197



Método

Tipo de modelo	Modelo de Tendência Linear
Dados	ocorrência
Tamanho	9
NFaltantes	0

Equação de Tendência Ajustada

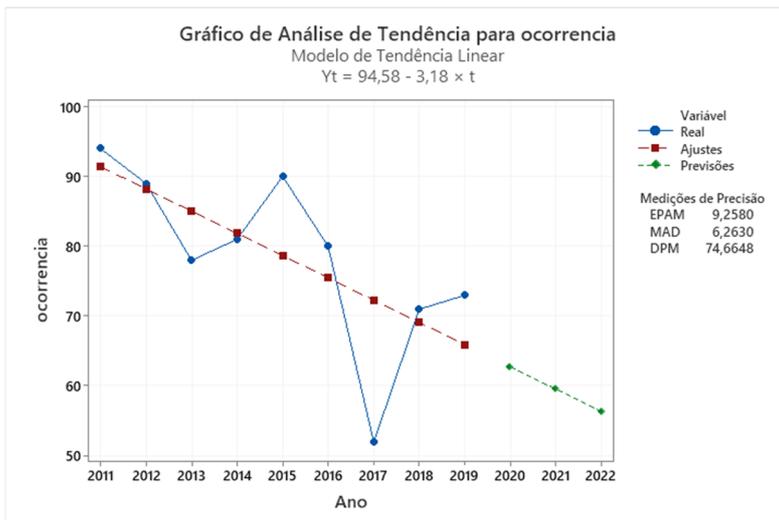
$$Y_t = 94,58 - 3,18 \times t$$

Medições de Precisão

EPAM	9,2580
MAD	6,2630
DPM	74,6648

Previsões

Período	Previsão
2020	62,7500
2021	59,5667
2022	56,3833



APÊNDICE III – Testes de tendência 3ª regional

Método

Tipo de modelo	Modelo de Tendência Quadrático
Dados	ocorrencias
Tamanho	9
NFaltantes	0

Equação de Tendência Ajustada

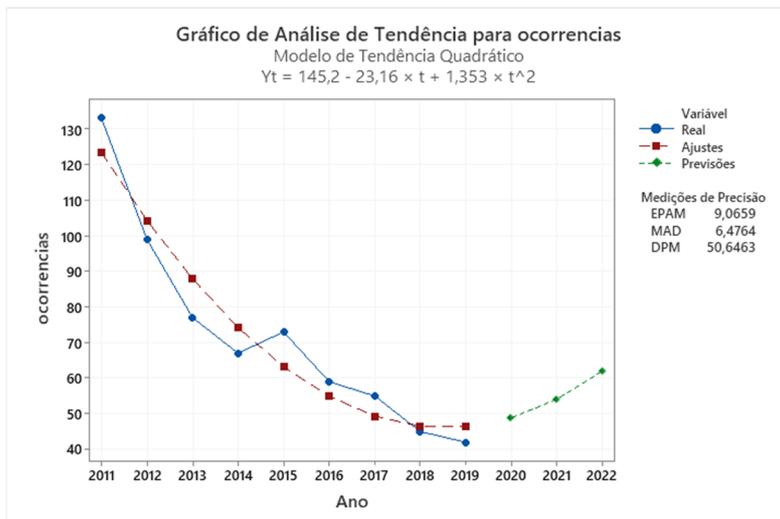
$$Y_t = 145,2 - 23,16 \times t + 1,353 \times t^2$$

Medições de Precisão

EPAM	9,0659
MAD	6,4764
DPM	50,6463

Previsões

Período	Previsão
2020	48,8571
2021	54,1048
2022	62,0580



Método

Tipo de modelo	Modelo de Tendência de Curva S
Dados	ocorrencias
Tamanho	9
NFaltantes	0

Equação de Tendência Ajustada

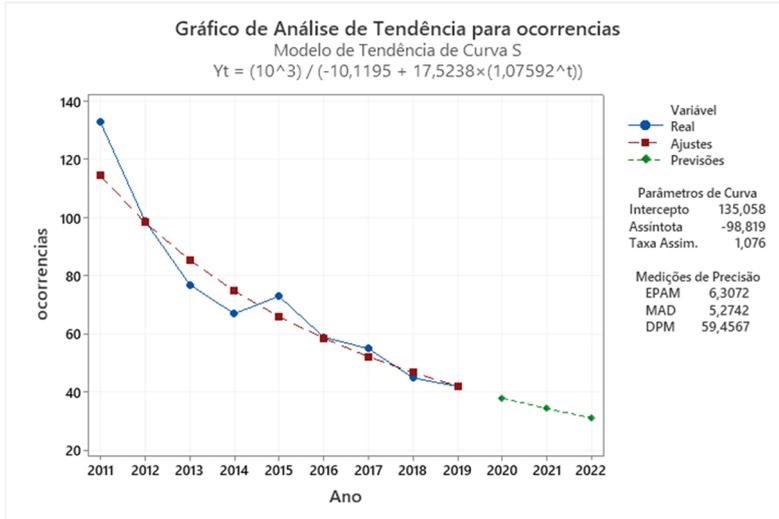
$$Y_t = (10^3) / (-10,1195 + 17,5238 \times (1,07592^t))$$

Medições de Precisão

EPAM	6,3072
MAD	5,2742
DPM	59,4567

Previsões

Período	Previsão
2020	38,0116
2021	34,3958
2022	31,2024



Método

Tipo de modelo Modelo de Tendência Linear
 Dados ocorrências
 Tamanho 9
 NFaltantes 0

Equação de Tendência Ajustada

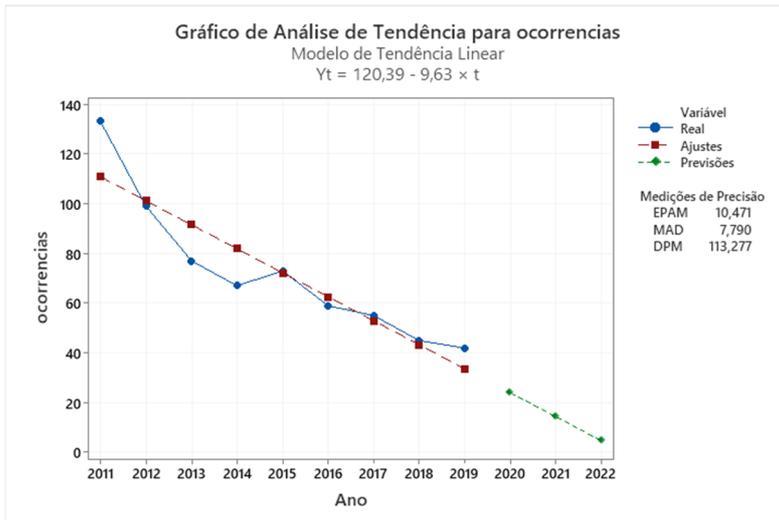
$Y_t = 120,39 - 9,63 \times t$

Medições de Precisão

EPAM 10,471
 MAD 7,790
 DPM 113,277

Previsões

Período	Previsão
2020	24,0556
2021	14,4222
2022	4,7889



APÊNDICE IV – *Script* de formatação dos dados para inserção no *software* WEKA

```

rm(list=ls())

gc()

install.packages("foreign")
install.packages("rgdal")
install.packages("raster")

library(foreign)
library(rgdal)
library(raster)

a<-
shapefile("D:/OneDrive/UNIFEI/Mestrado/Dissertacao/eCognition/GEOBIA_Dissertacao/corrigido/amostras_corrigido.shp") ## Apontar para o shape extraído pelo eCognition

b<-a@data

names(b) ## Localizar o nome da ultima coluna e o numero de sua posição
p<-b$Border_index ## Utilizar o nome do ultimo atributo
p1<-b$Class_name
b$Class_name<-p

b$Border_index<-p1 ## Utilizar nome do ultimo atributo

names(b)[36]<-"Border_index" ## Utilizar numero da posição de nome do ultimo atributo
names(b)[43]<-"Class_name" ## Utilizar o numero da ultima posição (coluna)

length(b[,1])

c<-subset(b, b$Class_name!="unclassified")

setwd("D:/OneDrive/UNIFEI/Mestrado/Dissertacao/eCognition/GEOBIA_Dissertacao/corrigido") ## Setar diretório de saída

write.csv(c, "amostras_corrigidos.csv", row.names = FALSE)

d<-b

b$Class_nam

d$Class_name<-"unclassified"

write.csv(d, "teste_corrigido_WEKAinput.csv", row.names = FALSE)

```

APÊNDICE V – Árvore de decisão

Scheme: weka.classifiers.trees.J48 -C 0.25 -M 2

Relation: amostras_corrigidos_WEKAinput

Instances: 4228

Attributes: 43

Ratio_band

Ratio_band.1

Ratio_band.2

Ratio_band.3

GLCM_Homog

GLCM_Homog.1

GLCM_Homog.2

GLCM_Homog.3

Contrast_t

Contrast_t.1

Contrast_t.2

Contrast_t.3

Visible_Br

NDVI

Min_pixel_

Min_pixel_.1

Min_pixel_.2

Min_pixel_.3

Max_diff

GLDV_Entro

GLDV_Entro.1

GLDV_Entro.2

GLDV_Entro.3

Standard_d

Standard_d.1

Standard_d.2

Standard_d.3

Mean_band_

Mean_band_.1

Mean_band_2
 Mean_band_3
 Max_pixel_
 Max_pixel_1
 Max_pixel_2
 Max_pixel_3
 Border_index
 Mean_Diff_1
 Mean_Diff_2
 Mean_Diff_3
 Compactnes
 Brightness
 Border_ind
 Class_name

Test mode: 10-fold cross-validation

=== Classifier model (full training set) ===

J48 pruned tree

NDVI <= 0.351434

| Standard_d.3 <= 38.896229

| | Min_pixel_3 <= 1511

| | | Ratio_band.2 <= 0.210606

| | | | Ratio_band <= 0.414384

| | | | | NDVI <= 0.274212: solo_exposto (632.0/5.0)

| | | | | NDVI > 0.274212

| | | | | GLCM_Homog.2 <= 0.006072: area_construida (3.0)

| | | | | GLCM_Homog.2 > 0.006072

| | | | | | Max_pixel_2 <= 1011

| | | | | | | Contrast_t.3 <= 40.87536

| | | | | | | | Standard_d.2 <= 13.993856

| | | | | | | | | Mean_band_3 <= 867.898734: solo_exposto (5.0)

| | | | | | | | | Mean_band_3 > 867.898734
 | | | | | | | | | Min_pixel_ <= 1341: Cultivo (7.0)
 | | | | | | | | | Min_pixel_ > 1341: solo_exposto (3.0)
 | | | | | | | | | Standard_d.2 > 13.993856: solo_exposto (47.0/2.0)
 | | | | | | | | | Contrast_t.3 > 40.87536: Cultivo (6.0/1.0)
 | | | | | | | | | Max_pixel_2 > 1011
 | | | | | | | | | Max_pixel_1 <= 1317: Vegetacao_rasteira (5.0/1.0)
 | | | | | | | | | Max_pixel_1 > 1317: solo_exposto (15.0/1.0)
 | | | | | | | | | Ratio_band > 0.414384
 | | | | | | | | | Ratio_band.2 <= 0.183109: solo_exposto (46.0/2.0)
 | | | | | | | | | Ratio_band.2 > 0.183109
 | | | | | | | | | GLDV_Entro.1 <= 4.518656: Vegetacao_rasteira (21.0/2.0)
 | | | | | | | | | GLDV_Entro.1 > 4.518656: solo_exposto (5.0)
 | | | | | | | | | Ratio_band.2 > 0.210606
 | | | | | | | | | Min_pixel_1 <= 673
 | | | | | | | | | Standard_d <= 121.4688: solo_exposto (5.0)
 | | | | | | | | | Standard_d > 121.4688
 | | | | | | | | | GLCM_Homog.1 <= 0.044536: Vegetacao_arborea (5.0)
 | | | | | | | | | GLCM_Homog.1 > 0.044536: Cultivo (2.0)
 | | | | | | | | | Min_pixel_1 > 673: area_construida (12.0)
 | | | | | | | | | Min_pixel_3 > 1511: area_construida (27.0)
 | | | | | | | | | Standard_d.3 > 38.896229
 | | | | | | | | | Ratio_band.2 <= 0.19292
 | | | | | | | | | Standard_d.3 <= 71.859761
 | | | | | | | | | GLDV_Entro.3 <= 3.495746: area_construida (3.0)
 | | | | | | | | | GLDV_Entro.3 > 3.495746
 | | | | | | | | | Min_pixel_ <= 2875
 | | | | | | | | | Contrast_t <= 217.120042: solo_exposto (41.0/2.0)
 | | | | | | | | | Contrast_t > 217.120042: area_construida (3.0/1.0)
 | | | | | | | | | Min_pixel_ > 2875: Vegetacao_rasteira (2.0/1.0)
 | | | | | | | | | Standard_d.3 > 71.859761: area_construida (15.0)
 | | | | | | | | | Ratio_band.2 > 0.19292
 | | | | | | | | | Ratio_band.3 <= 0.177267
 | | | | | | | | | Ratio_band.1 <= 0.298761: area_construida (9.0)

| | | | Ratio_band.1 > 0.298761: solo_exposto (10.0)
 | | | Ratio_band.3 > 0.177267: area_construida (918.0/2.0)
 NDVI > 0.351434
 | Mean_band_.2 <= 734.692308
 | | Min_pixel_.3 <= 797
 | | | Mean_band_.2 <= 706.093333: Vegetacao_arborea (704.0)
 | | | Mean_band_.2 > 706.093333
 | | | | Ratio_band.1 <= 0.075569: Cultivo (3.0)
 | | | | Ratio_band.1 > 0.075569
 | | | | | Min_pixel_.2 <= 591: Cultivo (3.0/1.0)
 | | | | | Min_pixel_.2 > 591: Vegetacao_arborea (41.0)
 | | | Min_pixel_.3 > 797
 | | | GLCM_Homog <= 0.015467: Vegetacao_arborea (7.0)
 | | | GLCM_Homog > 0.015467: Cultivo (9.0/1.0)
 | Mean_band_.2 > 734.692308
 | | Mean_band_.1 <= 817.02381
 | | | NDVI <= 0.503361
 | | | | Contrast_t.1 <= 21.543568
 | | | | | Mean_band_.2 <= 912.222222
 | | | | | | Visible_Br <= 750.848485: Vegetacao_arborea (3.0)
 | | | | | | Visible_Br > 750.848485
 | | | | | | | GLCM_Homog.2 <= 0.014239: solo_exposto (5.0)
 | | | | | | | GLCM_Homog.2 > 0.014239
 | | | | | | | | GLDV_Entro.2 <= 3.797858: solo_exposto (2.0/1.0)
 | | | | | | | | GLDV_Entro.2 > 3.797858
 | | | | | | | | | Min_pixel_.3 <= 847
 | | | | | | | | | Min_pixel_.2 <= 671: Cultivo (4.0/1.0)
 | | | | | | | | | Min_pixel_.2 > 671: solo_exposto (5.0)
 | | | | | | | | | Min_pixel_.3 > 847: Cultivo (23.0/2.0)
 | | | | | Mean_band_.2 > 912.222222: Vegetacao_rasteira (2.0)
 | | | | Contrast_t.1 > 21.543568
 | | | | | Ratio_band <= 0.420884: Cultivo (2.0/1.0)
 | | | | | Ratio_band > 0.420884: Vegetacao_rasteira (9.0/1.0)
 | | | NDVI > 0.503361

| | | | Standard_d.2 <= 41.000802
 | | | | | Contrast_t.2 <= 66.709167
 | | | | | | Max_pixel_.2 <= 970: Cultivo (391.0/4.0)
 | | | | | | Max_pixel_.2 > 970
 | | | | | | | Max_pixel_ <= 3712
 | | | | | | | | Min_pixel_ <= 3139
 | | | | | | | | | Max_pixel_.3 <= 990: Cultivo (57.0)
 | | | | | | | | | Max_pixel_.3 > 990
 | | | | | | | | | | Visible_Br <= 873.560284: Cultivo (6.0)
 | | | | | | | | | | Visible_Br > 873.560284: Vegetacao_rasteira (8.0/1.0)
 | | | | | | | | | | Min_pixel_ > 3139
 | | | | | | | | | | Compactnes <= 1.748053: Cultivo (3.0)
 | | | | | | | | | | Compactnes > 1.748053: Vegetacao_rasteira (6.0)
 | | | | | | | | | | Max_pixel_ > 3712: Cultivo (78.0)
 | | | | | | Contrast_t.2 > 66.709167
 | | | | | | | Mean_band_.2 <= 793.892857: Vegetacao_arborea (11.0)
 | | | | | | | Mean_band_.2 > 793.892857
 | | | | | | | | Contrast_t.3 <= 73.057802: Cultivo (29.0/1.0)
 | | | | | | | | Contrast_t.3 > 73.057802: Vegetacao_rasteira (3.0)
 | | | | | Standard_d.2 > 41.000802
 | | | | | | GLCM_Homog.2 <= 0.017511
 | | | | | | | GLDV_Entro <= 4.282905: Vegetacao_arborea (10.0)
 | | | | | | | GLDV_Entro > 4.282905
 | | | | | | | | Ratio_band <= 0.514233: Vegetacao_arborea (2.0)
 | | | | | | | | Ratio_band > 0.514233: Vegetacao_rasteira (4.0)
 | | | | | | | | GLCM_Homog.2 > 0.017511
 | | | | | | | | Min_pixel_.3 <= 805
 | | | | | | | | | Max_pixel_.2 <= 868: Cultivo (4.0)
 | | | | | | | | | Max_pixel_.2 > 868: Vegetacao_arborea (9.0)
 | | | | | | | | | Min_pixel_.3 > 805
 | | | | | | | | | Contrast_t.2 <= 135.72768
 | | | | | | | | | | GLDV_Entro.3 <= 4.406447: Cultivo (33.0)
 | | | | | | | | | | GLDV_Entro.3 > 4.406447
 | | | | | | | | | | Min_pixel_ <= 2167: Vegetacao_rasteira (3.0)

| | | | | | | | Min_pixel_ > 2167: Cultivo (4.0)
 | | | | | | | Contrast_t.2 > 135.72768: Vegetacao_rasteira (4.0/1.0)
 | | Mean_band_.1 > 817.02381
 | | | Standard_d.3 <= 43.918833
 | | | | Mean_band_.2 <= 954.25
 | | | | | Mean_band_.2 <= 885.722222
 | | | | | | Contrast_t.2 <= -54.961396: Cultivo (5.0)
 | | | | | | Contrast_t.2 > -54.961396
 | | | | | | | GLDV_Entro.2 <= 4.2554: solo_exposto (6.0)
 | | | | | | | GLDV_Entro.2 > 4.2554: Cultivo (4.0/1.0)
 | | | | | Mean_band_.2 > 885.722222
 | | | | | | Mean_band_.1 <= 936.563291
 | | | | | | | Max_pixel_.1 <= 1080
 | | | | | | | | Mean_band_.3 <= 922.058824: Cultivo (4.0)
 | | | | | | | | Mean_band_.3 > 922.058824
 | | | | | | | | | Max_pixel_.3 <= 1056: Vegetacao_rasteira (41.0/2.0)
 | | | | | | | | | Max_pixel_.3 > 1056: Cultivo (3.0)
 | | | | | | | | Max_pixel_.1 > 1080: Cultivo (11.0/1.0)
 | | | | | | Mean_band_.1 > 936.563291
 | | | | | | | Ratio_band.2 <= 0.18807: solo_exposto (5.0)
 | | | | | | | Ratio_band.2 > 0.18807: Vegetacao_rasteira (3.0)
 | | | | Mean_band_.2 > 954.25
 | | | | | Ratio_band.1 <= 0.152002
 | | | | | | Mean_band_.3 <= 1002.6
 | | | | | | | GLDV_Entro.1 <= 3.96157: Cultivo (7.0)
 | | | | | | | GLDV_Entro.1 > 3.96157
 | | | | | | | | GLDV_Entro <= 4.548594
 | | | | | | | | | GLCM_Homog.3 <= 0.021261
 | | | | | | | | | | Max_pixel_.3 <= 1024: Vegetacao_rasteira (19.0)
 | | | | | | | | | | Max_pixel_.3 > 1024
 | | | | | | | | | | | Standard_d.2 <= 23.164719: Cultivo (2.0)
 | | | | | | | | | | | Standard_d.2 > 23.164719: Vegetacao_rasteira (4.0)
 | | | | | | | | | | | GLCM_Homog.3 > 0.021261
 | | | | | | | | | | | Max_pixel_ <= 3514

| | | | | | | | | | Max_diff <= 1.463891
 | | | | | | | | | | Min_pixel_3 <= 912: Cultivo (6.0)
 | | | | | | | | | | Min_pixel_3 > 912: Vegetacao_rasteira (5.0/1.0)
 | | | | | | | | | | Max_diff > 1.463891: Vegetacao_rasteira (13.0)
 | | | | | | | | | | Max_pixel_ > 3514
 | | | | | | | | | | GLCM_Homog <= 0.027333: Cultivo (14.0/1.0)
 | | | | | | | | | | GLCM_Homog > 0.027333: Vegetacao_rasteira (2.0)
 | | | | | | | | | | GLDV_Entro > 4.548594
 | | | | | | | | | | Ratio_band.1 <= 0.147906: Cultivo (12.0)
 | | | | | | | | | | Ratio_band.1 > 0.147906: Vegetacao_rasteira (4.0/1.0)
 | | | | | | | | | | Mean_band_3 > 1002.6: Vegetacao_rasteira (24.0)
 | | | | | | | | | | Ratio_band.1 > 0.152002
 | | | | | | | | | | Standard_d.1 <= 106.055834
 | | | | | | | | | | Min_pixel_1 <= 989
 | | | | | | | | | | Min_pixel_3 <= 1018
 | | | | | | | | | | GLDV_Entro.2 <= 4.032453
 | | | | | | | | | | Contrast_t <= 21.698779
 | | | | | | | | | | Max_pixel_2 <= 1136
 | | | | | | | | | | GLCM_Homog.1 <= 0.013237: Cultivo (2.0)
 | | | | | | | | | | GLCM_Homog.1 > 0.013237
 | | | | | | | | | | Contrast_t <= 11.769945: Vegetacao_rasteira (27.0/1.0)
 | | | | | | | | | | Contrast_t > 11.769945: Cultivo (2.0)
 | | | | | | | | | | Max_pixel_2 > 1136: Cultivo (6.0)
 | | | | | | | | | | Contrast_t > 21.698779: Vegetacao_rasteira (45.0)
 | | | | | | | | | | GLDV_Entro.2 > 4.032453: Vegetacao_rasteira (361.0/10.0)
 | | | | | | | | | | Min_pixel_3 > 1018
 | | | | | | | | | | Ratio_band.3 <= 0.171717: Vegetacao_rasteira (6.0)
 | | | | | | | | | | Ratio_band.3 > 0.171717: Cultivo (5.0)
 | | | | | | | | | | Min_pixel_1 > 989: Vegetacao_rasteira (200.0/1.0)
 | | | | | | | | | | Standard_d.1 > 106.055834
 | | | | | | | | | | Min_pixel_1 <= 934
 | | | | | | | | | | GLDV_Entro.1 <= 4.433367: Vegetacao_rasteira (8.0)
 | | | | | | | | | | GLDV_Entro.1 > 4.433367: Cultivo (2.0)
 | | | | | | | | | | Min_pixel_1 > 934: solo_exposto (4.0)

```

| | | Standard_d.3 > 43.918833
| | | | Contrast_t <= 30.572548
| | | | | Ratio_band.2 <= 0.189133
| | | | | | Ratio_band.1 <= 0.192245: Cultivo (10.0)
| | | | | | Ratio_band.1 > 0.192245: solo_exposto (2.0)
| | | | | Ratio_band.2 > 0.189133: area_construida (2.0)
| | | | Contrast_t > 30.572548
| | | | | Compactnes <= 1.891733: area_construida (10.0/1.0)
| | | | | Compactnes > 1.891733: Vegetacao_rasteira (8.0/1.0)

```

Number of Leaves : 97

Size of the tree : 193

Time taken to build model: 0.52 seconds

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	3915	92.597 %
Incorrectly Classified Instances	313	7.403 %
Kappa statistic	0.9072	
Mean absolute error	0.0329	
Root mean squared error	0.1673	
Relative absolute error	10.2978 %	
Root relative squared error	41.8835 %	
Total Number of Instances	4228	

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,845	0,031	0,858	0,845	0,851	0,819	0,920	0,771	Cultivo
0,894	0,029	0,881	0,894	0,887	0,860	0,944	0,817	Vegetacao_rasteira

	0,930	0,017	0,931	0,930	0,930	0,913	0,958	0,864	solo_exposto
	0,977	0,007	0,979	0,977	0,978	0,971	0,985	0,970	area_construida
	0,968	0,008	0,965	0,968	0,966	0,958	0,980	0,939	Vegetacao_arborea
Weighted Avg.	0,926	0,018	0,926	0,926	0,926	0,908	0,959	0,877	

=== Confusion Matrix ===

```

a b c d e <-- classified as
645 75 23 2 18 | a = Cultivo
62 732 18 3 4 | b = Vegetacao_rasteira
21 17 782 16 5 | c = solo_exposto
4 3 15 982 1 | d = area_construida
20 4 2 0 774 | e = Vegetacao_arborea

```

APÊNDICE VI – *Scripts* de exportação da classificação

```
library(stringr)
```

```
library(rgdal)
```

```
library(raster)
```

```
arf<-
```

```
read.csv("D:/OneDrive/UNIFEI/Mestrado/Dissertacao/eCognition/GEOBIA_Dissertacao/corrigido/classificacao_062018_corrigido.csv", sep=",") ## selecione o arquivo exportado pelo Weka
```

```
a<-
```

```
shapefile("D:/OneDrive/UNIFEI/Mestrado/Dissertacao/eCognition/GEOBIA_Dissertacao/corrigido/amostras_corrigido.shp")
```

```
arf$predicted2<-str_split_fixed(arf$predicted, ":", 2)[,2]
```

```
a@data$Predicted_class<-arf$predicted2
```

```
shapefile(a, filename="classified_corrigido_06_2018.shp")
```

```
getwd()
```


APÊNDICE VIII – Teste estatístico ANOVA com comparação emparelhada de Tukey e comparações múltiplas Dunnett

Método

Hipótese nula	Todas as médias são iguais
Hipótese alternativa	Nem todas as médias são iguais
Nível de significância	$\alpha = 0,05$

Assumiu-se igualdade de variâncias para a análise

Informações dos Fatores

Fator	Níveis	Valores
classe	4	1; 2; 3; 4

Análise de Variância

Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
classe	3	50692806597	16897602199	644,58	0,000
Erro	48317	1,26663E+12	26214900		
Total	48320	1,31732E+12			

Sumário do Modelo

S	R2	R2(aj)	R2(pred)
5120,05	3,85%	3,84%	3,84%

Médias

classe	N	Média	DesvPad	IC de 95%
1	13819	484,63	1060,44	(399,26; 570,00)
2	17196	2676,7	8447,1	(2600,1; 2753,2)
3	13162	643,8	1305,6	(556,3; 731,2)
4	4144	414,7	643,6	(258,8; 570,6)

DesvPad Combinado = 5120,05

Comparações Emparelhadas de Tukey

Informações de Agrupamento Usando Método de Tukey e 95% de Confiança

classe	N	Média	Agrupamento
2	17196	2676,7	A
3	13162	643,8	B
1	13819	484,63	B
4	4144	414,7	B

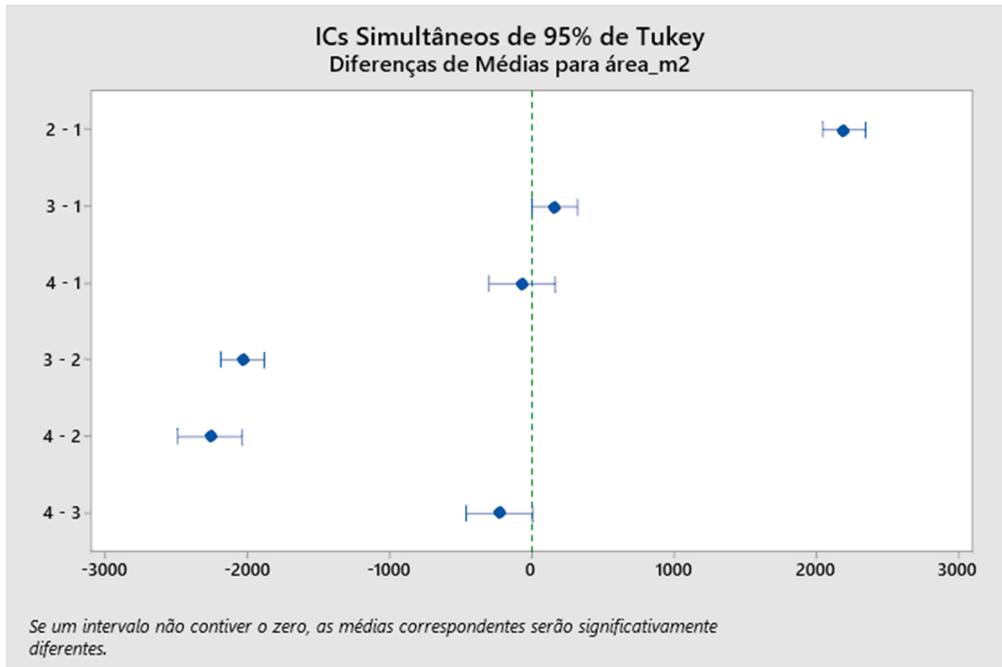
Médias que não compartilham uma letra são significativamente diferentes.

Testes Simultâneos de Tukey para as Diferenças de Médias

Diferença de Níveis	Diferença de Médias	EP da Diferença	IC de 95%	Valor-T	Valor-P Ajustado
2 - 1	2192,0	58,5	(2041,9; 2342,2)	37,47	0,000
3 - 1	159,1	62,4	(-0,9; 319,2)	2,55	0,052
4 - 1	-70,0	90,7	(-302,7; 162,8)	-0,77	0,867
3 - 2	-2032,9	59,3	(-2185,1; -1880,7)	-34,28	0,000
4 - 2	-2262,0	88,6	(-2489,4; -2034,6)	-25,53	0,000

4 - 3 -229,1 91,2 (-463,2; 5,0) -2,51 0,058

Nível de confiança individual = 98,97%



Comparações Múltiplas Dunnett com um Controle

Agrupar Informações Usando o Método de Dunnett e 95% de Confiança

classe	N	Média Agrupamento
2 (controle)	17196	2676,7 A
3	13162	643,8
1	13819	484,63
4	4144	414,7

As médias não rotuladas com a letra A são significativamente diferentes da média do nível de controle.

Testes Simultâneos de Dunnett para Média do Nível - Média de Controle

Diferença de Níveis	Diferença de Médias	EP da Diferença	IC de 95%	Valor-T	Valor-P Ajustado
1 - 2	-2192,0	58,5	(-2330,7; -2053,4)	-37,47	0,000
3 - 2	-2032,9	59,3	(-2173,4; -1892,4)	-34,28	0,000
4 - 2	-2262,0	88,6	(-2472,0; -2052,0)	-25,53	0,000

Nível de confiança individual = 98,22%

