

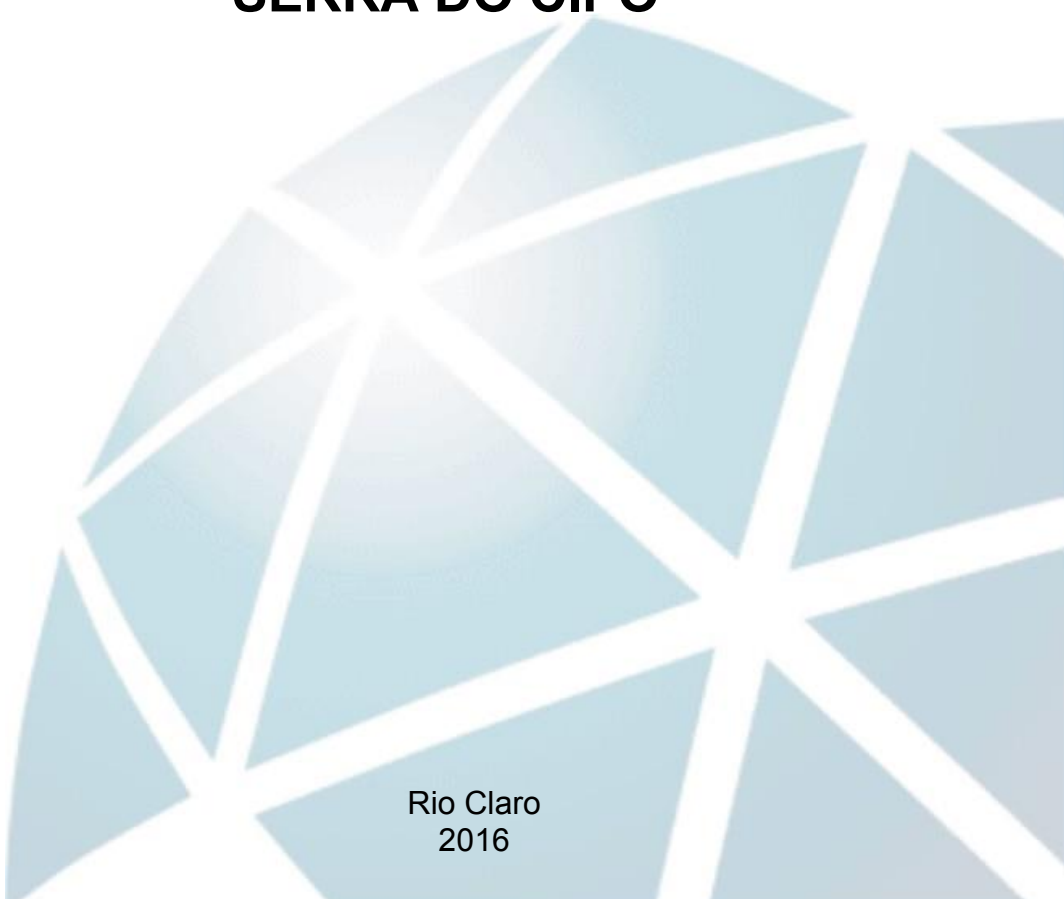
---

**ECOLOGIA**

---

**LUÍS FERNANDO DE CASTRO CAMPANHA**

**INFLUÊNCIA DA GEODIVERSIDADE SOBRE  
A DISTRIBUIÇÃO DE FISIONOMIAS DE  
VEGETAÇÃO NO PARQUE NACIONAL DA  
SERRA DO CIPÓ**



Rio Claro  
2016

LUÍS FERNANDO DE CASTRO CAMPANHA

INFLUÊNCIA DA GEODIVERSIDADE SOBRE A DISTRIBUIÇÃO DE  
FISIONOMIAS DE VEGETAÇÃO NO PARQUE NACIONAL DA SERRA  
DO CIPÓ

*Orientador: Prof. Dr. Thiago Sanna Freire Silva*

Trabalho de Conclusão de Curso apresentado ao  
Instituto de Biociências da Universidade Estadual  
Paulista “Júlio de Mesquita Filho” - Campus de  
Rio Claro, para obtenção do grau de Ecólogo

Rio Claro

2016

581.9 Campanha, Luís Fernando de Castro  
C186i      Influência da geodiversidade sobre a distribuição de  
fisionomias de vegetação no Parque Nacional da Serra do  
Cipó / Luís Fernando de Castro Campanha. - Rio Claro, 2016  
63 f. : il., figs., gráfs., tabs., quadros, fots., mapas

Trabalho de conclusão de curso (bacharelado - Ecologia)  
- Universidade Estadual Paulista, Instituto de Biociências de  
Rio Claro

Orientador: Thiago Sanna Freire Silva

1. Fitogeografia. 2. Fatores de distribuição da vegetação.  
3. Fitofisionomias. 4. Cerrado. 5. Rapideye. 6. Mapeamento.  
I. Título.

## AGRADECIMENTOS

Primeiramente, FORA TEMER urgente!

Agradeço primeiramente aos meus pais, Ginaldo e Paula, que além de todo amor e confiança, se esforçaram a vida toda para cuidar de mim e meu irmão, a quem também devo muito por inspiração e carinho. A primeira vez, ainda bem novo, que ouvi falar da ecologia, foi por meio do meu tio Rinaldo, também meu veterano. É uma grande inspiração de atitude e força, apesar de qualquer contratempo.

Os dois maiores amores que carrego no peito são frutos dos anos vividos em Rio Claro, tornam a vida ainda melhor e são responsáveis pelos melhores momentos dela. Paulinha, minha companheira para a vida, um exemplo de pessoa carinhosa e dedicada, amiga e responsável, admiração de todos que te conhecem. E Panceta, nossa cachorra maravilhosa e feliz, que viveu 5 lindos anos de carinho, mas infelizmente não pôde nos acompanhar para além da vida rio clarense. Saudades e lembranças dos momentos juntos.

Agradeço muito a Thiago Sanna Freire Silva, meu orientador, pela amizade e dedicação com seus alunos. Desde o estágio ao TCC, sempre esteve disponível a ajudar, tirar dúvidas e estimular o trabalho, grande pessoa. Não poderia deixar de fora os professores Milton Cezar Ribeiro e Maria Inez Pagani. Miltinho, também grande sujeito, importante demais para o futuro da Ecologia na UNESP, me garantiu diversas oportunidades, desde monitoria, projeto de extensão, até mesmo abrir a visão para a importância e amplitude da ecologia. Maria Inez é demais, gostaria de ter entrado em contato mais cedo na graduação. A UNESP Rio Claro tem sorte de ter professores como esses. Não posso esquecer de citar John Ribeiro, autor do software *Autoclass*.

Os grandes camaradas da República Sede, vivendo alguns anos juntos, mas para sempre acompanhando a caminhada. Por tantos momentos importantes, desde aqueles mais engraçados, as conversas e debates, e até momentos de crises e discussões, vocês são FODA PRA CARALHO: Renato Trevisan, Maria Zupelari, Anderson Akio Mizu, Jaqueline Coguetto, Pedro Henrique BH, Roberta Curan, Josué Lodi Zucão, Felipe Zanatta, Felipe Comitre Fantoche, Gabriela Bortolozzo, Leo Tomazine, Francisco Chagas Chicão, Lincoln Gonçalves, e os cachorros Cora e Bolt.

Os parceiros da Bomba, Rodolfo Medeiros e Tiago Pavesi Morsa, valeu pelo tempo

juntos, falando besteira, se divertindo e também discutindo, crescendo juntos. Os últimos anos de república foram com eles e, apesar de percalços, não poderia ter sido melhor. Só tenho admiração por eles. Há muito por vir.

A todos do EcoDyn, pela amizade e sempre ajudando no desenvolvimento do trabalho: Swanni Alvarado, Annia Streher, Rafaela Niemann, Beatriz Daunt, João Sobreiro, Carlos Leandro Cordeiro, Bruno Luize, Camila Casella, Sayuri Sugai e Jefferson Ferreira-Ferreira.

Antes tarde do que nunca, dedico à Ecologia 2010. Não poderia ter caído numa sala melhor: Xica, Batuba, Xernobil, Miyagi, Pedrota, Nômade, Flora, Gorfo, Bel, Mooca, Pitanga, Jessica, Kaori, Mandi, Gabilon, Nhoque, Bala, Kanelinha, Quiri, Origami e Zhu.

A todos os funcionários, que diariamente, e por vezes passando despercebidos, fazem essa universidade funcionar. Um agradecimento em TCC ainda é muito pouco para o que merecem.

Jamila Prata, grande amiga, já de longa data, me recebeu em Rio Claro e foi responsável por me apresentar a algumas das pessoas que mais admiro. Além de garantir o primeiro teto em Rio Claro. Carlos Alberto Bola, Tiago Salge Beraba, Joana Rubinsteinn, Pedro Monarcha, Lucas e Jonas Meirelles, Julia Janczur, Tais Martins, assim como tantos outros amigos da UNESP e dos tempos do colégio, que se fosse citar daria outro TCC.

## RESUMO

A abordagem empregada para a conservação da biodiversidade tem focado principalmente em uma escala fina, de espécies. Mas esta visão pode não ser capaz de contemplar os efeitos das mudanças globais, por não integrar os aspectos da geodiversidade. É o que pretende a abordagem chamada de “Conservação do Palco da Natureza” (“Conserving the Nature’s Stage”, CNS), ao incluir a noções de que uma maior diversidade do ambiente físico, configurando refúgios e microclimas, é condição primordial para a geração e manutenção da diversidade biológica. A análise geográfica de imagens orientada a objetos (GEOBIA) é uma forma de análise automática de imagens de sensoriamento remoto, apropriada para a classificação da cobertura em imagens de alta resolução espacial. Esta metodologia é particularmente indicada para classificação de paisagens heterogêneas, como os mosaicos de vegetação da Cadeia do Espinhaço, Brasil. A GEOBIA foi empregada no presente trabalho para gerar o mapa da vegetação da região do PARNA da Serra do Cipó e da APA Morro da Pedreira. Foram testadas formas automatizadas para produzir tal mapa. Com a distribuição das fitofisionomias desta região de Cerrado, podemos relacionar a sua ocorrência de acordo com a localização de padrões geológicos e topográficos, e verificar se a geodiversidade pode, neste caso e escala, ser empregada para auxiliar o planejamento da conservação. A segmentação automática foi essencial no processo, de modo a agilizar e reduzir o viés do analista, no entanto, devido à grande extensão da área e complexidade de fitofisionomias foram reconhecidos erros, demandando posterior correção manual. A taxa de erro *Out-of-Bag* foi alta, 38,8%, demonstrando que os números de amostras de treinamento deveriam ser maiores, e a segmentação mais refinada. Contudo, o algoritmo *Random Forest* foi capaz de distinguir relativamente bem as fitofisionomias semelhantes. Apresentamos ainda as relações da morfometria do relevo com a presença de cada classe. Por fim, expomos a relação da localização das Unidades Geológico-Ambientais com a distribuição das classes de vegetação e cobertura do solo, onde temos quatro categorias de Geodiversidade representando as classes de vegetação, uma sendo bem relacionada a Afloramento Rochoso.

## SUMÁRIO

1.	INTRODUÇÃO E FUNDAMENTAÇÃO TEÓRICA.....	6
1.1	Geodiversidade .....	6
1.2	Sensoriamento remoto e análise geográfica de imagens orientada a objetos .....	9
2.	OBJETIVOS.....	12
3.	MATERIAIS E MÉTODOS.....	13
3.1	Descrição da área de estudo.....	13
3.2	Mapeamento da Vegetação .....	14
3.3	Processamento das imagens e Classificação automática .....	19
3.3.1	Correção atmosférica.....	19
3.3.2	Segmentação das imagens .....	19
3.3.3	Extração de atributos das imagens .....	20
3.4	Atributos morfométricos.....	26
3.5	Geodiversidade .....	28
4.	RESULTADOS E DISCUSSÃO .....	31
4.1	Segmentação .....	31
4.2	Classificação Automática.....	31
4.3	Classificação automática e correção manual .....	34
4.4	Morfometria do relevo.....	39
4.5	Geodiversidade .....	47
5.	CONCLUSÃO.....	51
	REFERÊNCIAS .....	54
	APÊNDICE .....	61

## 1. INTRODUÇÃO E FUNDAMENTAÇÃO TEÓRICA

A abordagem atualmente mais aceita nos estudos e empregada para a preservação da biodiversidade é baseada na conservação de espécies ou de comunidades, variando pelo nível da análise, da escala do estudo. Muitos planejamentos para a conservação definem áreas prioritárias a partir da rica presença de espécies endêmicas (LAWLER et al. 2015). Contudo, com a crescente preocupação com as mudanças globais, esta interpretação pode não ser capaz de representar as necessidades de conservação a longo prazo e para escalas mais amplas. A abordagem por espécies depende também de estudos que são muitas vezes dispendiosos e exaustivos, pela necessidade de coletar e analisar uma grande variedade de espécies, o que diversas vezes não é possível. As mudanças nos embasamentos, estruturas geológicas e do relevo ocorrem em escalas temporais muito superiores que a da vida humana. Assim, pensar em conservar este cenário, no qual as espécies interagem e evoluem, pode ser importante para garantir condições futuras mais duradouras de manutenção da vida na Terra (ANDERSON e FERREE, 2010; BEIER e BROST, 2010; LAWLER et al. 2015).

No presente trabalho, buscaremos trabalhar com o conceito de geodiversidade e compreender como este pode influenciar a distribuição de fitofisionomias características do cerrado brasileiro, em uma região de alta diversidade biológica. O sensoriamento remoto é ferramenta essencial para estas análises, e assim utilizaremos da análise geográfica de imagens orientada a objetos para otimizar o processo de produção de informações geográficas.

### 1.1 Geodiversidade

O conceito de geodiversidade é uma proposta razoavelmente nova, e ainda pouco explorada por biólogos da conservação (BEIER, HUNTER e ANDERSON, 2015). A definição mais aceita deste conceito pertence a Gray (2004, p. 8, tradução do autor):

Geodiversidade: a variedade natural (diversidade) de características geológicas (rochas, minerais, fósseis), feições geomorfológicas (forma de terras, processos) e do solo. Inclui seus conjuntos, relações, propriedades, interpretações e sistemas.

Esta abordagem, ao conceber a diversidade de formas do relevo, sua composição e processos, nos permite inferir a distribuição da biodiversidade associada a esses fatores abióticos.

Segundo a Royal Society for Nature Conservation do Reino Unido, podemos definir a geodiversidade como a “variedade de ambientes geológicos, fenômenos e processos ativos que dão origem a paisagens, rochas, minerais, fósseis, solos e outros depósitos superficiais que são o suporte para a vida na Terra” (BRILHA, 2005, p. 17). Por sua vez, o Serviço Geológico do Brasil, CPRM, expressa:

Geodiversidade é a natureza abiótica (meio físico) constituída por uma variedade de ambientes, fenômenos e processos geológicos que dão origem às paisagens, rochas, minerais, águas, solos, fósseis e outros depósitos superficiais que propiciam o desenvolvimento da vida na terra, tendo como valores intrínsecos a cultura, o estético, o econômico, o científico, o educativo e o turístico.

A geodiversidade, assim, contempla os elementos físicos que constituem o relevo e que se relacionam aos processos de transformação e evolução destes elementos. Ruban (2010, p. 327, tradução do autor) ressalta que, por definição, a geodiversidade pode ser quantificada simplesmente pela “quantidade total de tipos de geosítios ocorrendo em um determinado território”. O mesmo autor define geosítio como um lugar de significativa herança, monumento ou objeto de patrimônio geológico, exposto na superfície terrestre e acessível à visitação e estudos (RUBAN, 2010, p. 326, tradução do autor).

Em 1959, Hutchinson já havia abordado conceitos semelhantes quando descrevia o nicho ecológico como o “Conjunto de condições e recursos requeridos pelas espécies para sobreviver, foco nos fatores abióticos locais e a distribuição de recursos alimentares. Latitude, elevação, geologia, solo e topografia influenciam o clima e a disponibilidade de recursos, e juntos definem a composição das espécies” (HUTCHINSON, 1959 apud LAWLER et al. 2015). Diversos fatores geofísicos seriam então responsáveis, primeiramente, por permitir a ocorrência de espécies e comunidades em determinadas localidades assim como seu deslocamento em busca de melhores condições. Anderson e Ferree (2010) relatam que, essencialmente, os padrões de diversidade de espécies são moldados pela geologia, pois esta influencia as propriedades químicas e físicas do solo e da água, e forma diferentes topografias que, por sua vez, interferem nas condições climáticas locais, gerando padrões que podem ser preditos.

Da abordagem de geodiversidade em conjunto com o propósito da conservação da biodiversidade surge a ideia de “conservação do palco da natureza“ (*Conserving Nature's Stage*) (BEIER, HUNTER e ANDERSON, 2015). Esta seria uma abordagem para a

conservação da biodiversidade como um todo, com foco em áreas com maior diversidade abiótica, que ofereceriam suporte para um maior número de espécies e habitats viáveis em decorrência de um conjunto complexo de fatores abióticos e consequentemente diversificação de nichos. Assim, considera-se que a biota presente nestes ambientes estaria bem representada nos planejamentos de conservação atuais, mas que também perdurariam no futuro (LAWLER et al. 2015), pelo fato de que características físicas do ambiente são mais duradouras, ou persistem inalteradas em uma escala de tempo maior que a dos animais e plantas, garantindo condições semelhantes no futuro. Hunter e colaboradores já haviam ressaltado o suporte para o planejamento ambiental de conservação que esta abordagem traria, apontando que “ambientes físicos como arenas de atividade biológica, ao invés de comunidades, para os ocupantes temporários dessas arenas” (HUNTER, 1988 apud BEIER, HUNTER e ANDERSON, 2015).

As configurações topográficas, como formas de montanhas e vales, criam microclimas e refúgios em situações de mudanças climáticas (DOBROWSKI, 2011). Estes ambientes apresentam condições mais estáveis em virtude da diversidade topográfica, agindo como refúgios para muitas espécies. Áreas assim tem sido associadas a uma rápida diversificação de espécies. A combinação da geologia, tipos de solo, elevação e declividade podem afetar processos de especiação e extinção, pois determinadas regiões geram oportunidades para interações interespecíficas (LAWLER et al. 2015). A diversidade de ambientes físicos, portanto, permite maior variedade de condições ambientais. Assim, também maior será o espaço do nicho para as espécies ocuparem ou se diferenciarem. Garantir a preservação de fatores geofísicos, em conjunto a processos ecológicos, é importante para assegurar as condições atuais dos ecossistemas e permitir que outros locais possam ser ocupados no futuro (COMER et al. 2015).

Beier et al. (2015) apresentou uma revisão demonstrando como a diversidade abiótica (dita geodiversidade e variabilidade climática em conjunto) é capaz de representar bem as espécies. Plantas são melhor representadas por estes elementos, mas atualmente já é possível definir a distribuição de plantas, vertebrados e organismos marinhos (BEIER, HUNTER e ANDERSON, 2015). Anderson e seus colaboradores (2015) levantaram oito estudos de caso que incorporaram a abordagem de geodiversidade aos planos de conservação tradicionais, encontrando que as áreas prioritárias para se tornarem unidades de conservação ou áreas protegidas não foram modificadas significativamente. Contudo, o uso da geodiversidade poderia ser empregado como alternativa complementar, compatível com as necessidades destes

planos atuais, de baixo custo e maior simplicidade. As variáveis topográficas e geológicas, por exemplo, já estão mapeadas para diversas regiões, isto reduz consideravelmente o esforço amostral.

A proposta de conservar o palco da natureza foca em escalas maiores de biodiversidade, o filtro grosseiro (*coarse-filter* – HUNTER et al. 1988), ao invés de concentrar esforços para apenas conservar espécies individualmente, o filtro fino (SHAFFER, 2015). Mas muito depende da influência da escala espacial. Diferentes níveis de análise formarão conjuntos de condições variados. Assim, como destaca Lawler (2015), para dimensões continentais a regionais, o clima será o fator preponderante para a distribuição das espécies. Do nível regional a paisagem, solos e topografia são mais influentes. Da paisagem ao local, interações bióticas e perturbações ao ambiente controlam a distribuição.

O planejamento para a conservação poderia assim ser fortalecido por esta abordagem, recebendo maior apoio legal ao emprego da geodiversidade nos estudos. A Convenção da Diversidade Biológica, através das metas de Aichi 2020, contempla esta visão ao expor dois itens. A meta cinco trata de reduzir as taxas de perda de habitat e a meta onze em garantir suficiente representação ecológica por áreas e águas protegidas (COMER et al. 2015).

## 1.2 Sensoriamento remoto e análise geográfica de imagens orientada a objetos

O monitoramento ambiental é uma estratégia importante para garantir a conservação, pois permite dimensionar os danos e frequência de ações nocivas a ambientes naturais, protegidos ou não. Desmatamento, queimadas e outras modificações da superfície, naturais ou antrópicas, vem sendo observados por sistemas de sensoriamento remoto (ROY, LEWIS e JUSTICE, 2002; REICHE et al. 2015; SCHULTZ et al. 2016). A observação de fogos ativos ou áreas queimadas por sensoriamento remoto, por exemplo, tem sido feita por sensores de média a baixa resolução espacial (100 a 1000 metros), como AVHRR, SPOT VEGETATION, EOS MODIS, e MERIS, que contudo possuem alta resolução temporal – levam de um a cinco dias para coletar informações de toda superfície terrestre (ROLLINS et al. 2004). Este *trade-off* entre resolução espacial e temporal permite monitorar áreas quase que diariamente, sacrificando a capacidade de identificação de pequenos objetos. Em áreas com cobertura de nuvens menos frequente, sensores de média resolução espacial, como os sensores da série LANDSAT (30m), podem ser utilizados, porém com sacrifício da resolução temporal (16 dias para a revisita) (USGS, 2016). Assim, as perdas e ganhos no uso de cada tipo de sensor devem

ser avaliadas para cada aplicação.

O sensoriamento remoto foi muito aprimorado desde as fotografias aéreas, tiradas a partir de balões, até o lançamento de satélites e desenvolvimento de sensores, radares e técnicas de análise da paisagem (ARVOR et al. 2013; BLASCHKE, HAY e KELLY, 2014). A abordagem clássica de elaboração de mapas ou a análise dos elementos que compõem a paisagem é exaustiva e subjetiva. Assim, nos anos 1980 o conceito de análise de imagens orientada a objeto (OBIA) foi introduzido como abordagem nos Sistemas de Informações Geográficas (SIG), e também evoluiu muito em conjunto com a tecnologia e capacidade de processamento de dados computacionais (DRAGUT e BLASCHKE, 2006).

O trabalho de interpretação visual de imagens e delineamento manual de classes temáticas pode ser longo e minucioso, devido à extensão da região estudada e à quantidade de informações extraídas. Assim, o desenvolvimento de técnicas de processamento automático e classificação digital de imagens é essencial para reduzir o viés do analista e seu esforço (MENESES e ALMEIDA, 2012). É neste sentido que o método da análise geográfica de imagens orientada a objetos (GEOBIA) foi desenvolvido.

**A análise geográfica de imagens orientada a objetos (GEOBIA)** é uma subdisciplina da *Ciência de Informação Geográfica* (GIScience) dedicada a desenvolver métodos automatizados para segmentar imagens de sensoriamento remoto em significativos objetos-imagem, e atribuir suas características através de escalas espaciais, espectrais e temporais, de modo a gerar novas informações geográficas em um formato SIG imediato (HAY e CASTILLA, 2008, p. 77, tradução do autor).

As abordagens de classificação e análise de imagens de sensoriamento remoto por muito tempo focaram em informações e estatísticas extraídas dos *pixels* das imagens, baseando-se apenas em características espectrais, sem incluir informações de contexto, *i.e.* do objeto ao qual o *pixel* pertence, desconsiderando assim tamanho, forma e disposição. Estes elementos eram então tradicionalmente introduzidos na análise apenas através da interpretação visual do analista (DRAGUT e BLASCHKE, 2006). A abordagem da GEOBIA se baseia no delineamento automático de objetos, apresentados como polígonos (*shapes*), no processo chamado de segmentação de imagens. Os objetos delineados são representações de unidades homogêneas da paisagem (*facies*), e representam de forma mais clara a composição e estrutura da superfície. Assim, a GEOBIA se aproxima mais da realidade do que a análise baseada em

*pixels*, pois os objetos identificados na análise das imagens são facilmente relacionados à estrutura e composição da paisagem (ZHANG et al. 2013). Cleve e seus colaboradores (2008), Maxwell e Warner (2015) demonstram como a análise de imagens por objetos é indicada para uma boa classificação do uso e cobertura do solo utilizando imagens de alta resolução, como as imagens RapidEye (MAXWELL e WARNER, 2015).

Arvor e colaboradores (2013) ressaltam importantes problemas em aspectos científicos presentes neste tipo de análise. Por ser baseado no conhecimento de especialistas, alguns passos do processo podem não ser documentados, tornando difícil a replicação do método por diferentes pesquisadores. Isto é, a interpretação das imagens ainda é dependente do analista, e não tanto do método. Mesmo variações da percepção humana por viés, experiência e até filtros biofísicos, como a visão, poderiam comprometer a análise (BLASCHKE et al. 2014). No entanto os autores citam, inclusive, que a característica marcante da GEOBIA é a produção de resultados iguais ou até melhores que a simples percepção humana permite. A escala também é um componente que gera preocupação no momento da segmentação e classificação. A variedade de formas e componentes da paisagem exige o uso de diversas escalas espaciais, mas mesmo assim a segmentação representa apenas áreas relativamente homogêneas, em relação à radiação refletida pelos objetos. Ao comparar o processo da segmentação em múltiplas escalas e por análise de objetos e segmentação por pixels, Zhang e colaboradores (2013) demonstraram que são inevitáveis a sub- ou sobre-segmentação. Ou seja, a escolha de uma única escala não abrange toda a variedade de características da paisagem, mas múltiplas escalas podem extrapolar a segmentação, gerando polígonos que representam parte de uma mesma estrutura da paisagem.

## 2. OBJETIVOS

A análise da paisagem pode ser aperfeiçoada com o uso de técnicas automatizadas em todo o processo. E é neste sentido que a segmentação automática e a classificação semi-automática foram utilizadas neste estudo, visando reduzir problemas com a escala e o viés do observador. Assim, pretendeu-se contribuir com a compreensão dos processos ambientais que controlam a distribuição e a dinâmica da vegetação na Cadeia do Espinhaço, auxiliando sua conservação.

Assim, o presente projeto teve por objetivo principal compreender a influência da topografia e geodiversidade sobre a ocorrência e distribuição de fisionomias vegetais na região compreendida pelo Parque Nacional da Serra do Cipó e Área de Proteção Ambiental Morro da Pedreira (MG).

Para tanto, buscou-se avaliar, a partir do conceito de geodiversidade, como variáveis físicas, geologia e relevo, influenciam a ocorrência e distribuição de fisionomias de vegetação do Cerrado e Floresta Atlântica na região, a partir de um mapa de fitofisionomias e cobertura do solo do mosaico de vegetação do Parque Nacional da Serra do Cipó e da Área de Proteção Ambiental Morro da Pedreira (MG), produzido por um método de classificação semi-automática.

### 3. MATERIAIS E MÉTODOS

#### 3.1 Descrição da área de estudo

O Parque Nacional da Serra do Cipó (criado em 1978 como Parque Estadual e alterado para Parque Nacional em 1984) e a Área de Proteção Ambiental (APA) Morro da Pedreira, que o circunda (criada em 1990) encontram-se no Estado de Minas Gerais (coordenadas 19°10' - 19°40'S e 43°30' - 43°55'W), à cerca de 100 km da capital Belo Horizonte, no sentido Nordeste. O PARNA da Serra do Cipó possui uma extensão de 31.617 ha. (RIBEIRO e FIGUEIRA, 2011), e a APA Morro da Pedreira, que exerce função de zona de amortecimento ao Parque, tem 131.769,37 ha. (ICMBIO).

A região do estudo (Figura 1) está inserida na porção Sul da Cadeia do Espinhaço, região de alta diversidade biológica e importância ecológica, sendo reconhecida como Reserva da Biosfera (UNESCO, 2005). A Cadeia do Espinhaço possui cerca de 1100 km de extensão no sentido Norte-Sul, entre os estados de Minas Gerais e Bahia, variando aproximadamente entre 20 e 100 km de largura no sentido Leste-Oeste. Este importante orógeno compreende um mosaico de diferentes paisagens, apresentando fitofisionomias de três biomas brasileiros, Caatinga, Cerrado e Mata Atlântica (CARVALHO et al. 2012). No entanto, fisionomias do Cerrado, como matas secas, campos rupestres e campos de altitude são muito recorrentes. O campo rupestre, composto principalmente por gramíneas e afloramentos rochosos, é um dos tipos de vegetação mais característicos, mas também compõem a paisagem fragmentos de Mata Atlântica Semidecidual e cerrado *sensu stricto* (ECHTERNACHT et al. 2011). Especificamente na região da Serra do Cipó predominam as fisionomias de Cerrado; os campos rupestres acima dos 900 m de altitude, campos limpos, cerrado *sensu stricto*, cerradão, mata ciliar e matas úmidas (PIRANI et al. 2015).

O clima local é definido como tropical de altitude, com variação na precipitação entre 1300 e 1600 mm ao longo do ano. Duas estações são bem definidas, sendo de maio a setembro/outubro os meses secos, com amplitude térmica de 13° a 37°C, e de outubro/novembro a março/abril o período chuvoso, com variação nas temperaturas médias entre 15° e 37°C (GALVÃO e NIMER, 1965 apud RIBEIRO e FIGUEIRA, 2011).

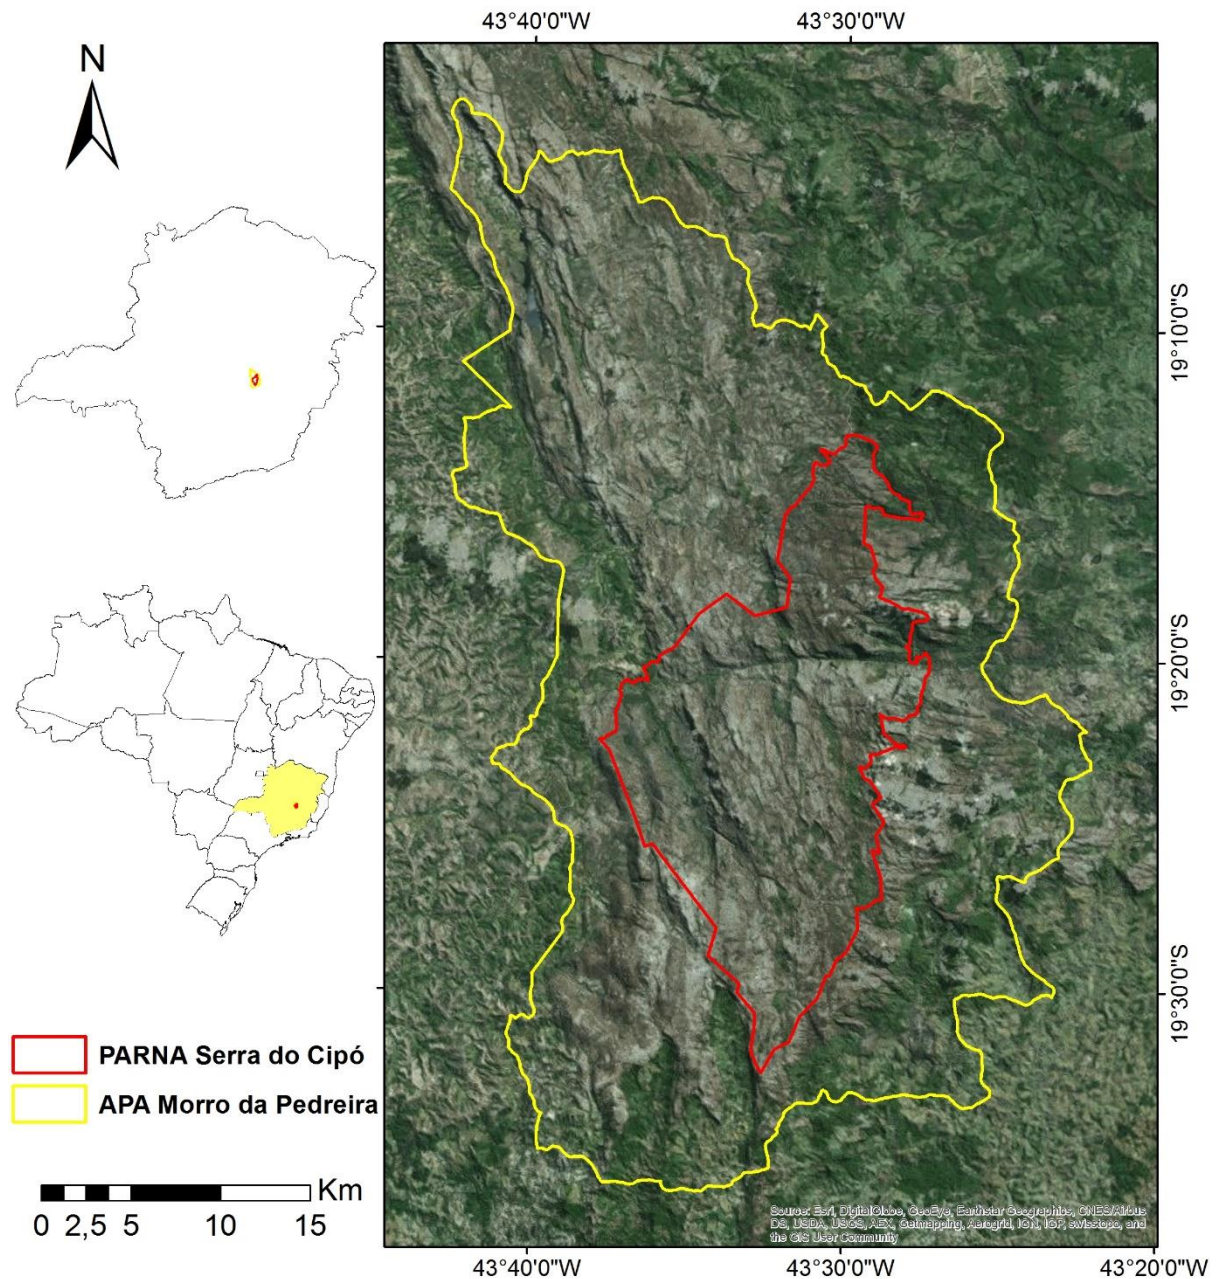


Figura 1 – Mapa de localização da área de estudo. Fonte: Elaborado pelo autor.

### 3.2 Mapeamento da Vegetação

A área de estudo compreende um mosaico de diferentes paisagens, contemplando fisionomias de mata atlântica, cerradão, cerrado *stricto sensu*, matas secas, campos rupestres, campos de altitude, campos úmidos, campos limpos, e campos sujos, além das áreas de exploração agrícola e zonas urbanas. Para o mapeamento da vegetação, foi necessário criar uma legenda de classes que correspondesse às fitofisionomias da região, e ao mesmo tempo respeitasse as limitações de resolução espacial e espectral das imagens. Devido ao complexo

comportamento espectral de cada uma destas fisionomias e à dificuldade de diferenciá-las nas imagens, optou-se por utilizar uma legenda hierárquica de classes de uso e cobertura do solo. Inicialmente, determinamos duas categorias amplas, vegetado e não-vegetado. Estas subdividem-se de acordo com o padrão da vegetação ou ocupação do solo. Para a vegetação ainda foi possível refinar a legenda em mais um nível (Tabela 1):

Tabela 1 – Legenda de classificação hierárquica.

		Floresta Estacional
	Arbóreo	Mata Ciliar
		Mata Seca/Cerradão
Vegetado		Cerrado sensu-strictu
	Arbustivo-Herbáceo	Campo Sujo
		Afloramento Rochoso
	Herbáceo	Campo Limpo
		Água
Não-vegetado	Não-vegetado	Rocha Exposta
		Solo Exposto
		Urbano

A definição da legenda de classificação pretendeu abranger uma variedade importante de tipos de vegetação, que pudessem englobar de forma genérica outros tipos. Caso pretendêssemos corresponder exatamente a cada fisionomia presente no Cerrado, o número de classes seria muito superior, dificultando a classificação e elaboração do mapa.

A diferenciação entre as fitofisionomias seguiu critérios baseados primeiramente na forma da vegetação, e depois em aspectos do ambiente e florísticos. Aqui empregamos seis tipos vegetacionais e quatro de cobertura do solo. Abaixo apresentamos definições para as fitofisionomias utilizadas (SANO, ALMEIDA e RIBEIRO, 2008; GONÇALVES, 2015):

- Afloramento Rochoso: fitofisionomia herbácea-arbustiva. Aqui a definição se assemelha ao Campo Rupestre, ocorrendo a partir de 700 m de altitude. Por vezes, indivíduos lenhosos concentram-se em fendas de rochas. Devido condições restritivas deste ambiente é comum a ocorrência de endemismos e plantas raras;

- Campo Limpo: fisionomia predominantemente herbácea, com raros arbustos. É encontrado com frequência em encostas, chapadas e na borda de matas de galeria. Também chamado de Campo de Várzea quando ocorre próximos a rios e inundado periodicamente;
- Cerrado/Campo Sujo: tipo de vegetação arbóreo-arbustivo, com presença de árvores baixas, inclinadas, tortuosas, com ramificações irregulares e retorcidas. Ocorre maior espaçamento entre indivíduos, variando para subtipos, de 20% a 70% de cobertura arbórea e altura de até 8 m. Incluímos o Campo Sujo pela semelhança na identificação nas imagens de sensoriamento remoto, apesar de ser predominantemente arbustivo;
- Floresta Estacional: fisionomia arbórea, em geral tida como de transição entre zonas úmidas e ambientes mais áridos, como entre a Mata Atlântica e o Cerrado. Também reconhecida como Floresta Tropical Seca. Ocorre perda das folhas no período seco;
- Mata Ciliar: vegetação florestal, arbórea que acompanha os rios de médio e grande porte, mas não formando galerias. Dificilmente passa dos 100 m de largura em cada margem. Pode haver transição pouco evidente entre outras fisionomias, como a Mata Seca;
- Mata Seca/Cerradão: unimos duas fisionomias de formações florestais, arbóreas, sem associação com cursos de água. A composição de espécies abrange tanto aquelas que ocorrem no cerrado *sensu stricto* e em formações florestais, variando em altura de 8 a 25 m;

Para o mapeamento, foi utilizado um conjunto de imagens de alta resolução dos satélites RapidEye, disponibilizadas pelo sistema Geo Catálogo, do Instituto Brasileiro do Meio Ambiente e Recursos Renováveis – IBAMA (<http://geocatalogo.ibama.gov.br/>). O sistema RapidEye é uma constelação de cinco satélites que possui resolução espacial de 5m e resolução temporal entre 1 e 5,5 dias, dependendo se a observação for feita como *off-nadir* ou *nadir* – com ou sem apontamento direcional<sup>1</sup> (ANTUNES e SIQUEIRA, 2013). O sensor à bordo dos satélites possui cinco bandas espectrais, localizadas nas regiões do azul (440-510 nm), verde (520-590 nm), vermelho (630-685 nm), *red-edge* (limite do vermelho) (690-730 nm) e

---

<sup>1</sup> O apontamento direcional é o direcionamento do sensor para observar cenas laterais à órbita do satélite. A observação *off-nadir* utiliza o apontamento direcional, o que aumenta a área recoberta pelo sensor (INPE, 2006).

infravermelho próximo (760-850 nm) do espectro eletromagnético. Cada cena possui 25 km por 25 km, com sobreposição de 500 metros com cenas vizinhas (Figura 2). A alta resolução espacial das imagens RapidEye pode auxiliar na avaliação de diversas regiões, nos mais variados temas que o sensoriamento remoto pode contemplar, como o monitoramento da vegetação, de queimadas, de dinâmicas da paisagem, expansão urbana, etc.

O banco de dados disponibilizado no sistema Geo Catálogo foi adquirido pelo Ministério do Meio Ambiente visando atender demandas expostas pelo Novo Código Florestal (BRASIL, 2012), e por meio do Programa de Regularização Ambiental (PRA - instituído pelo Decreto Presidencial 7.830/2012), mas é também disponibilizado para pesquisas acadêmicas. O PRA é resultado do Novo Código Florestal. Entre as modificações em relação ao seu antecessor, foi estabelecido o Cadastro Ambiental Rural (CAR), um registro eletrônico de todos os imóveis rurais do país, que pretende formar uma base de dados da situação fundiária e ambiental destes imóveis. Assim, esta plataforma conterá informações - documentos de posse, a delimitação e quantidade em área - georreferenciadas de Áreas de Preservação Permanente (APP), Reserva Legal (RL) e remanescentes de vegetação nativa, de modo a auxiliar no controle e monitoramento do desmatamento e da situação das propriedades rurais no Brasil. Desta forma, o PRA tem entre seus objetivos principais dispor estas imagens para gerar informações geoespaciais e estatísticas ambientais.

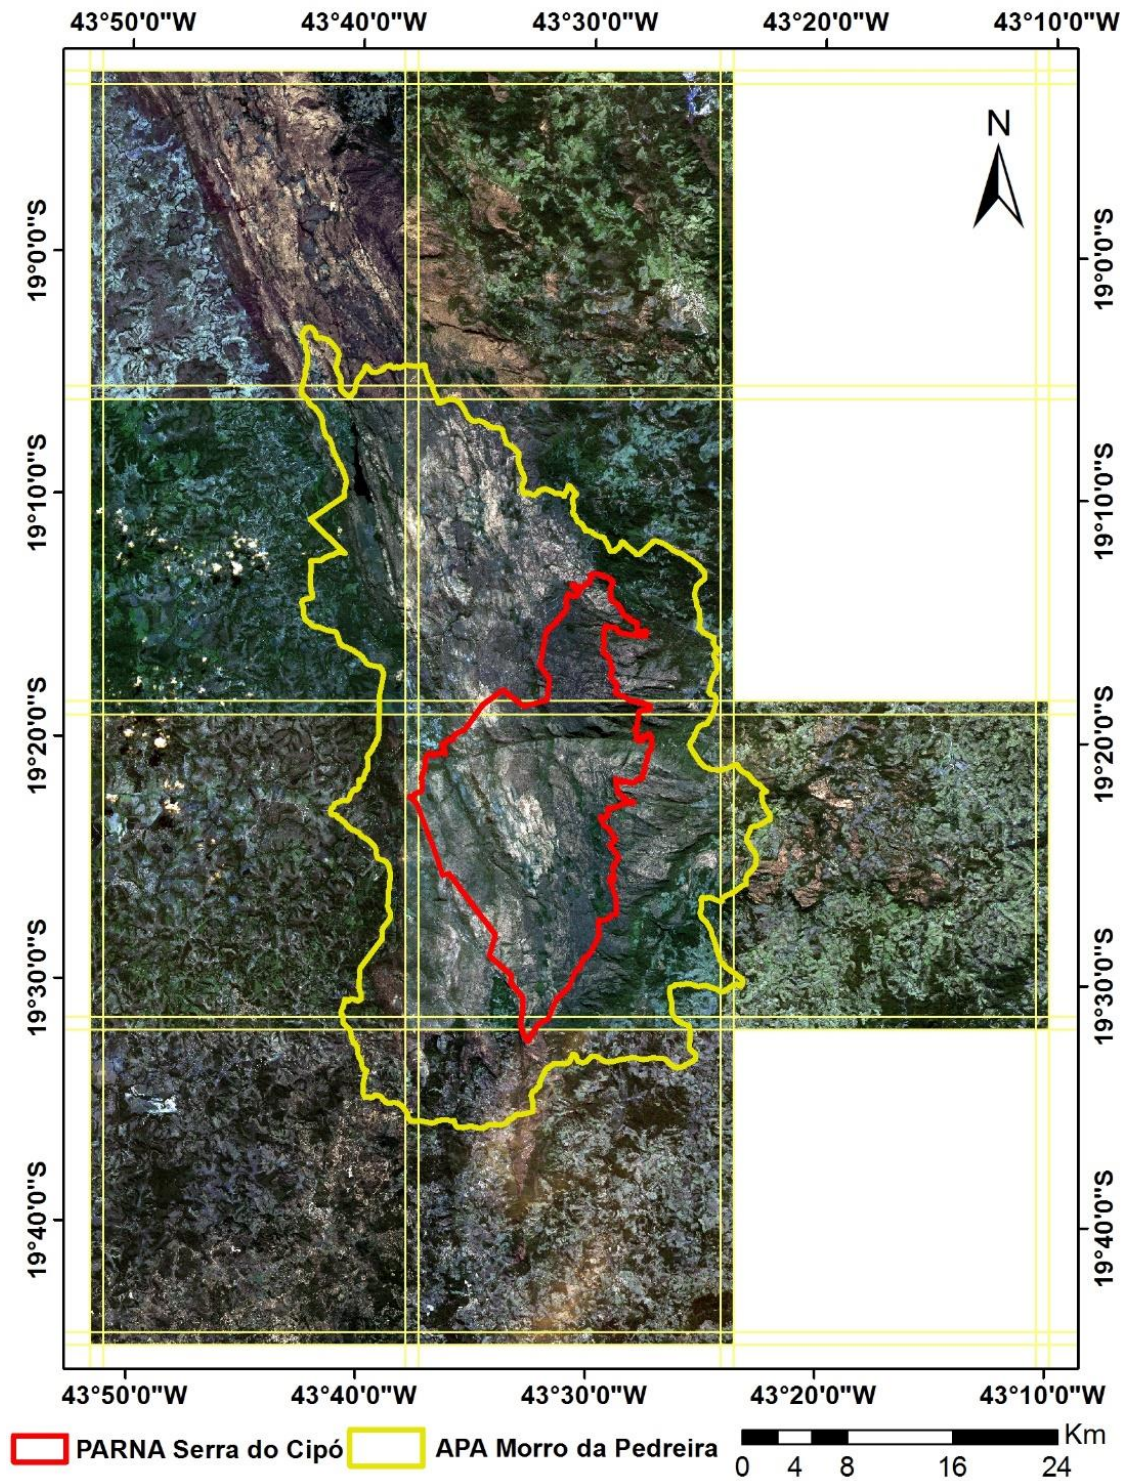


Figura 2 – Cobertura e sobreposição entre as cenas *RapidEye* adquiridas para o presente estudo. Imagem: composição colorida de cor real utilizando as bandas R3G2B1. Fonte: Elaborado pelo autor.

Para recobrir toda a região do Parque Nacional da Serra do Cipó e da Área de Proteção Ambiental Morro da Pedreira foram necessárias imagens correspondentes à nove cenas RapidEye (Apêndice). O sistema Geo Catálogo possui imagens adquiridas em diversas datas, contudo nem todas apresentam boa qualidade para a interpretação, pois contêm grandes proporção de nuvens ou artefatos. As imagens selecionadas para uso no presente estudo são apresentadas na Tabela 2. Durante a seleção, buscou-se ao máximo adquirir imagens da mesma estação do ano, a fim de minimizar variações devido ao estágio fenológico da vegetação.

### 3.3 Processamento das imagens e Classificação automática

#### 3.3.1 Correção atmosférica

O primeiro processamento das imagens foi a correção atmosférica pelo software ENVI, utilizando o algoritmo “Quick Atmospheric Correction - QUAC” (Correção Atmosférica Rápida). O QUAC é um método de correção atmosférica para imagens multiespectrais e hiperespectrais que determina parâmetros atmosféricos de compensação a partir das informações contidas nas imagens, em cada um de seus pixels. Esta etapa permitiu minimizar os efeitos de variações nas condições atmosféricas e de iluminação sobre as imagens (ENVI, 2009).

#### 3.3.2 Segmentação das imagens

Em seguida realizamos o primeiro processamento automatizado, empregando o Segmentador de Imagens Digitais *Autoclass* (RIBEIRO e VANCINE, 2015). Este software foi desenvolvido a partir de um Sistema de Informação Geográfica (SIG), GRASS 7.0.0, e um pacote de análise estatística de dados, R versão 2.15.3. O processo de segmentação das imagens ocorre pelo agrupamento de *pixels* com valores de cinza semelhantes em uma mesma região. Alguns parâmetros devem ser definidos para executar o algoritmo de segmentação, como a quantidade de imagens a serem processadas, o número esperado de classes de objeto, o limiar (*threshold*) (valor que varia entre 0 e 1 para definir o agrupamento dos segmentos - em 0 são agrupados apenas os segmentos essencialmente iguais, em 1 todos os segmentos são agrupados - um único segmento para toda a imagem) e *Minsize* (número mínimo de pixels por objeto). Foram processadas 9 imagens, sendo determinadas 15 classes (a fim de suportar heterogeneidades dentro das dez classes definidas para a legenda de mapeamento), com *threshold* de 0.25 e *Minzise* de 200 pixels. O arquivo de saída é vetorial (*shapefile*). Este

arquivo possui as mesmas dimensões da imagem *raster* de entrada, portanto, de modo a reduzir o tamanho do arquivo e o tempo dos processamentos posteriores, cada resultado foi recortado com base no perímetro da APA Morro da Pedreira, obtido pelo arquivo vetorial contendo os limites da área.

Tabela 2 – Lista das imagens utilizadas. A busca por imagens no sistema Geo Catálogo necessita do município de referência e do ID (identificação da imagem no sistema, refere-se à cena). O dia em que cada imagem foi registrada encontra-se na última coluna.

<b>Município</b>	<b>ID</b>	<b>Data da Imagem</b>
Santana do Riacho	2330020	27/07/2013
Nova União	2330021	02/05/2014
Jaboticatubas	2330120	05/05/2013
Jaboticatubas	2330121	04/08/2013
Itambé do Mato Dentro	2330122	04/08/2013
Jaboticatubas	2330220	01/05/2013
Morro do Pilar	2330221	04/08/2013
Santana do Riacho	2330320	12/10/2012
Conceição do Mato Dentro	2330321	04/08/2013

### 3.3.3 Extração de atributos das imagens

Com os objetos da imagem criados, podemos obter uma variedade de informações espectrais e espaciais de cada objeto (MAXWELL e WARNER, 2015). Assim, estas características, atributos estatísticos, foram extraídas de cada uma das nove imagens RapidEye que recobrem a APA Morro da Pedreira e o PARNA da Serra do Cipó, a partir dos polígonos criados no passo anterior. Esta etapa foi desenvolvida pelo software QGIS 2.8.1, com o uso da ferramenta *Zonal Statistics* (estatísticas zonais). Os atributos foram obtidos para cada uma das cinco bandas do espectro do visível (azul, verde, vermelho, vermelho limite e infravermelho próximo) de cada uma das nove imagens, totalizando 45 processos de extração de atributos.

A ferramenta *Zonal Statistics* calcula os valores de *pixels* de um arquivo *raster* (imagens RapidEye) com base em uma camada vetorial de polígonos (arquivo *shape* gerado na etapa anterior). Assim, ao final do processo são adicionadas à tabela de atributos do arquivo *shape*

colunas com estatísticas calculadas para cada polígono, com base nos *pixels* que estão dentro do polígono. Foram nove estatísticas calculadas (Figura 3) para as cinco bandas do espectro do visível, resultando em um total de 45 atributos de entrada para classificação.

<b>Sigla</b>	<b>Significado</b>	<b>Função</b>
Min	Mínimo	Obter os valores mínimos dos <i>pixels</i>
Max	Máximo	Obter os valores máximos dos <i>pixels</i> .
Sum	Soma	Somar os valores dos <i>pixels</i> .
Count	Contagem	Contar o número de <i>pixels</i> .
Mean	Média	Obter a média dos valores de <i>pixels</i> .
StDev	Desvio Padrão	Obter o desvio padrão dos valores de <i>pixels</i> .
Unique	Valores Únicos	Obter os <i>pixels</i> com valores únicos.
Range	Alcance	Obter o alcance, diferença entre valores mínimos e máximos dos <i>pixels</i> .
Var	Variedade	Contar o número de valores de pixel distintos.

Figura 3 – Quadro com as estatísticas calculadas pela ferramenta Zonal Statistics do software QGIS 2.8.1. As siglas representam cada coluna adicionada à tabela de atributos, sendo que ainda são inseridos prefixos relativos a cada uma das cinco bandas do espectro do visível utilizadas.

#### 3.3.4 Amostras de treinamento

O processo de classificação automática depende de amostras de treinamento para programar o algoritmo a diferenciar as classes de fitofisionomias. As amostras foram selecionadas com base em três métodos: por fotos georreferenciadas de campo, por interpretação de imagens de alta resolução das bases GoogleEarth e Bing Maps, e pela experiência do analista adquirida em campo (Figura 4). As fotos georreferenciadas foram obtidas em diversas visitas a campo realizadas entre 2015 e 2016. A partir do software GeoSetter (<http://www.geosetter.de/>) é possível visualizar as fotos como pontos sobrepostos às imagens da base Google Earth, bem com a direção em cada foto tiradas e seu ângulo de visada, permitindo assim identificar a vegetação em determinada região (Figura 5). Os pontos das fotos podem ser exportados em formato *kmz* (Google Earth) ou para um arquivo vetorial (*shapefile*).

O arquivo *shapefile* contendo os objetos delineados foi submetido à classificação manual dos objetos a serem utilizados como amostras de treinamento, em um total de 1245 amostras, distribuídos da seguinte forma: Afloramento Rochoso (n=143); Água (n=51); Campo Limpo (n=236); Cerrado/Campo Sujo (n=92); Floresta Estacional (n=175); Mata Ciliar (n=127); Mata Seca/Cerradão (n=119); Rocha Exposta (n=174); Solo Exposto (n=66); Urbano (n=62).








Figura 4 - Exemplos de amostras de referência: Fotos - a) Afloramento rochoso; b) Água; c) Campo Limpo; d) Cerrado/Campo Sujo; e) Mata Ciliar; f) Mata Seca/Cerradão; Imagens do Google Earth - g) Afloramento; h) Água; i) Campo Limpo; j) Cerrado/Campo Sujo; k) Floresta Estacional; l) Mata Ciliar; m) Mata Seca/Cerradão; n) Rocha Exposta; o) Solo Exposto; p) Urbano. Fonte: Elaborado pelo autor.




Figura 5 – Layout do software GeoSetter com os pontos indicando fotos georreferenciadas no mapa.

### 3.3.5 Classificação automática

A classificação automática das imagens foi gerada pelo algoritmo *Random Forests*, e se baseou nos nove arquivos vetoriais contendo os objetos referentes às cenas que recobrem a área de estudo. Este algoritmo se baseia na construção de várias árvores de decisão para seleção

de variáveis e classificação. As árvores de decisão seguem uma estrutura binária, em que sucessivos critérios são selecionados em cada nó, para o crescimento da árvore. A cada nó de crescimento um conjunto de atributos candidatos para separação é comparado, e o atributo que oferece melhor separação é selecionado. Ao se variar o número e composição dos atributos candidatos para cada nó, milhares de árvores de decisão diferentes podem ser geradas. Ao final do processo, a classe final de cada objeto será definida pela classe de maior consenso entre todas as árvores geradas (BREIMAN, 2001; GISLASON, BENEDIKTSSON e SVEINSON, 2006). O classificador requer dois parâmetros, o número de árvores de classificação que se pretende gerar, e o número de variáveis preditoras (atributos) consideradas como candidatas para definição de cada nó. A Figura 6 demonstra como ocorre o processo de seleção de variáveis pelo algoritmo *Random Forests*.

Durante a classificação, dentro do conjunto inicial de amostras de treinamento, um subconjunto é separado como *Out-of-bag* (OOB, "fora do saco"). As amostras OOB são utilizadas pelo algoritmo para avaliar a performance da classificação, comparando a classificação de treinamento com a classe predita pelo algoritmo, produzindo uma estimativa de erro não enviesada. Um terço do conjunto de dados é separado aleatoriamente para formar o conjunto OOB. O método *RandomForest* faz uma estimativa da importância de cada variável ao prever a quantidade de aumento de erro (OOB) quando parte dos dados da variável são permutados, enquanto o restante permanece estável (BREIMAN, 2001; LIAW e WIENER, 2002; GISLASON, BENEDIKTSSON e SVEINSSON, 2006; GALIANO et al. 2012a; GALIANO et al. 2012b). A partir dos erros OOB, é possível obter uma matriz de confusão, que representa os acertos e tipos de erros que foram encontrados pelo classificador. A matriz de confusão é definida de forma que cada termo dentro dela indica o percentual de diagnósticos que a classe predita (coluna) corresponde a classe real (linha) (Tabela 4). Assim, a diagonal da matriz de confusão indica o total de acertos (acurácia global) da classificação (cruzamento da mesma classe) e os termos fora da mesma apontam a incidência dos diferentes tipos de erro possíveis (cruzamento de classes diferentes) (DANTAS, 2015). Além disso, é possível calcular a acurácia relativa de cada classe (Class Error), comparando-se a proporção de acertos e erros para cada classe. O resultado final das medidas de acurácia é expresso em valores entre 0 e 1. Ao multiplicá-los por 100, obtemos o resultado em porcentagem.

O procedimento da classificação se deu no software R Studio, versão 1.0.28 ((R STUDIO TEAM, 2016). Foram carregados os pacotes *raster* (BIVAND et al., 2016) e *rgdal* (HIJMANS et al, 2016) – que permitem ao software R Studio ler arquivos *raster* e vetoriais -

e o pacote *randomForest* (LIAW e WIENER, 2015) – o qual aplica o algoritmo de treinamento e classificação -, e em seguida inseridos os arquivos *shapefile* de cada uma das nove cenas. Indicamos quais linhas da tabela com os atributos e amostras de referência deveriam ser lidas, para que apenas as amostras classificadas fossem utilizadas no treinamento. Uma vez que cada cena RapidEye foi segmentada separadamente, reunimos ao final todas as amostras de treinamento em uma única tabela, incluindo todos os 1245 polígonos classificados no treinamento. Configuramos o algoritmo *Random Forest* para produzir 10 mil árvores de decisão ( $n_{tree} = 10000$ ) e o número de variáveis candidatas por nó em seis ( $m_{try} = 6$ ).

### 3.3.6 Correção Manual

Ao término da classificação automática pelo algoritmo *RandomForest*, foi realizada a correção manual do mapa produzido, utilizando o software QGIS 2.8.1. Esta etapa foi importante para garantir a qualidade do produto final, em que as classes de vegetação e cobertura do solo determinadas correspondessem ao máximo à realidade, e assim comparar qual foi efetivamente a taxa de acerto da classificação automática, e analisar a composição da paisagem. A escala de visualização foi mantida em 1:2500, a fim de manter a consistência no nível de detalhamento do delineamento manual ao longo da imagem.

### 3.4 Atributos morfométricos

Para geração dos atributos morfométricos, adquirimos um modelo digital de elevação (DEM – *Digital Elevation Model*) oriundo da missão *Shuttle Radar Topography Mission* (SRTM), disponível no site <http://earthexplorer.usgs.gov/>, pertencente ao serviço geológico dos Estados Unidos da América. Esta missão, encabeçada pela NASA e NGA (Administração Nacional Aeronáutica e Espacial, e Agência Nacional de Inteligência Geoespacial, respectivamente) adquiriu informações topográficas para toda a superfície terrestre. A imagem *raster* utilizada neste trabalho pertence à versão mais recente dos dados, apresentando resolução espacial de um arco-segundo (cerca de 30 metros) (NASA, 2016).

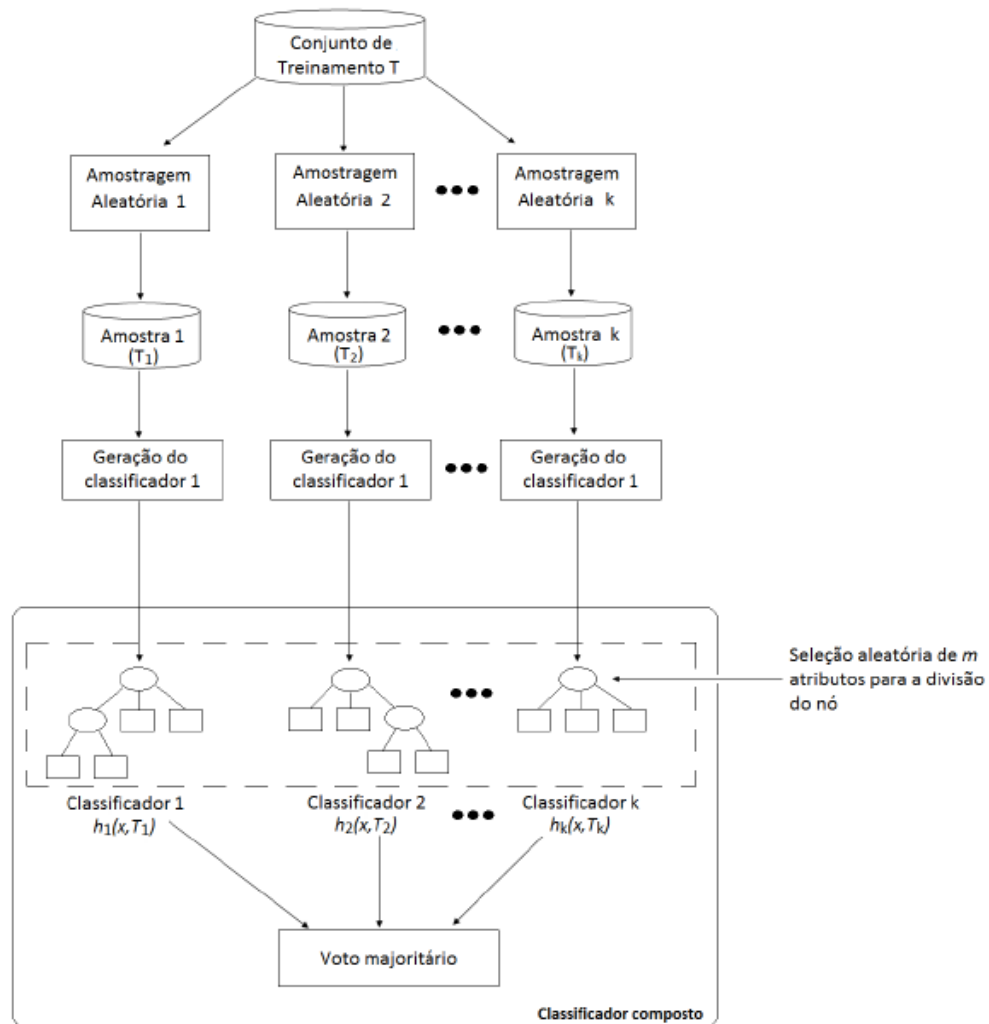


Figura 6 – Esquema hipotético do processo de classificação pelo algoritmo *RandomForest*.  
Fonte: Adaptado de Oshiro (2013, p. 17).

A partir deste *raster* é possível gerar uma série de índices morfométricos do terreno (altitude, declividade, orientação de vertente, sombreamento, curvatura e TWI – índice de umidade topográfico). Mas apenas foram calculados altitude, declividade (*slope*) e orientação de vertente (*aspect*). As informações do relevo estão contidas em cada *pixel* destas imagens *raster*. Nesta etapa foi empregado o software QGIS 2.14.3, com a ferramenta *DEM (Terrain Models)*.

Em seguida, as informações de cada *pixel* para altitude, declividade e orientação de vertente foram extraídas para cada um dos objetos do mapa de vegetação e cobertura do solo, elaborado nas etapas anteriores. Assim, cada objeto vinculado à um padrão da paisagem pôde ser contextualizado com características do relevo.

### 3.5 Geodiversidade

A análise da geodiversidade foi realizada com base no mapeamento de geodiversidade do Brasil, componente do Projeto SIG Geologia Ambiental do Brasil ao Milionésimo, do Serviço Geológico Brasileiro (CPRM, 2006). Mais especificamente foi utilizado o material que compõe o Mapeamento de Geodiversidade do Estado de Minas Gerais. Este material foi produzido com base no Mapa Geológico do Estado de Minas Gerais, na escala de 1:1.000.000, e no Mapa de Geodiversidade do Brasil, na escala de 1:2.500.000, além de levantamentos em campo e bibliográfico. Apresenta o território do Estado mineiro dividido em cinco domínios geológico ambientais, 62 unidades geológico-ambientais e 17 classes de relevo, de acordo com a definição dos conjuntos estratigráficos (MARCHADO e SILVA, 2010).

Para reduzir o tamanho do arquivo do Mapeamento de Geodiversidade, este foi cortado de acordo com a área de interesse, pelo perímetro da APA Morro da Pedreira. Assim, o recorte utilizado passou a conter nove unidades geológico-ambientais e as mesmas 17 classes do relevo (Figura 7). Por fim, os mapas de geodiversidade e de vegetação e cobertura do solo foram sobrepostos, no software QGis 2.8.1, para obtermos as sobreposições de classes e assim calcular a proporção em que cada classe de vegetação compõe cada uma das unidades geológico-ambiental.

Domínio	Unidades geológico-ambientais	Relevo	Declividade	Geo_Rel	Leg.
Domínio dos sedimentos cenozóicos inconsolidados ou pouco consolidados, depositados em meio aquoso.	Ambiente de planícies aluvionares recentes - Material inconsolidado e de espessura variável que da base para o topo é formado por cascalho, areia e argila.	Planícies fluviais ou flúvio-lacustres	0 a 3º	DCa/R1a	1
Domínio das coberturas sedimentares proterozóicas, não ou muito pouco dobradas e metamorfizadas.	Predomínio de sedimentos, siltico-argilosos com intercalações subordinadas de rochas calcárias.	Domínio montanhoso	25 a 45º	DSP1sac/R4c	2
		Domínio de morros e de serras baixas	25 a 45º	DSP1sac/R4b	3
		Domínio de colinas dissecadas e morros baixos	5 a 20º	DSP1sac/R4a2	4
		Domínio de colinas amplas e suaves	3 a 10º	DSP1sac/R4a1	5
Domínio das sequências sedimentares proterozóicas dobradas, metamorfizadas em baixo grau a médio grau	Metarenito, quartzitos e metaconglomerados.	Domínio montanhoso	25 a 45º	DSP2mqmtc/R4c	6
		Domínio de morros e de serras baixas	15 a 35º	DSP2mqmtc/R4b	7
	Predomínio de metarenitos e quartzitos, com intercalações irregulares de metassedimentos siltico-argilosos e formações ferríferas ou manganêsíferas.	Domínio montanhoso	25 a 45º	DSP2mqsafmg/R4c	8
	Intercalações irregulares de metassedimentos arenosos e siltico-argilosos.	Domínio montanhoso	25 a 45º	DSP2msa/R4c	9
	Predomínio de metassedimentos siltico-argilosos, com intercalações de metagrauvacas.	Domínio montanhoso	25 a 45º	DSP2sag/R4c	10
	Predomínio de metacalcários, com intercalações subordinadas de metassedimentos siltico-argilosos e arenosos	Domínio montanhoso	25 a 45º	DSP2mcsaa/R4c	11
		Domínio de colinas amplas e suaves	3 a 10º	DSP2mcsaa/R4a1	12
	Domínio dos corpos máficos-ultramáficos (suítes	Série básica e ultrabásica (gabro e anortosito,	Domínio montanhoso	25 a 45º	DCMUbu/R4c

Domínio	Unidades geológico-ambientais	Relevo	Declividade	Geo_Rel	Leg.
komatiíticas, suítes toleíticas, complexos bandados) - Ex (Cana Brava, Barro Alto e Niquelândia); básicas e ultrabásicas alcalinas e vulcanismo associado	etc).	Domínio de colinas dissecadas e morros baixos	5 a 20 <sup>a</sup>	DCMUbu/R4a2	14
		Domínio montanhoso	25 a 45 <sup>a</sup>	DCGMGLgno/R4c	15
Domínio dos complexos granito-gnaissé-migmatítico e granulitos	Predominam gnaissé ortoderivado. Podem conter porções migmatíficas.	Domínio de colinas dissecadas e morros baixos	5 a 20 <sup>a</sup>	DCGMGLgno/R4a2	16
		Domínio de morros e de serras baixas	15 a 35 <sup>a</sup>	DCGMGLgno/R4b	17

Figura 7 – Quadro com a estrutura hierárquica das Unidades geológico-ambientais, classes do relevo e declividade. Geo\_Rel: código que representa a relação das classes de Unidades geológicos-ambientais e do relevo, é o campo indexador que liga a tabela aos polígonos do mapa de geodiversidade ao banco de dados (CPRM, 2010), é a legenda utilizada para as análises.

## 4. RESULTADOS E DISCUSSÃO

### 4.1 Segmentação

A segmentação foi bastante eficaz em identificar os elementos da paisagem e agilizar o processo do mapeamento. O *output* do segmentador *Autoclass* foram os arquivos vetoriais delimitando os objetos relacionados às classes de vegetação e cobertura do solo. No total, as nove imagens *RapidEye* foram segmentadas em 67.738 polígonos. Mas como utilizamos apenas o recorte pelo perímetro da APA Morro da Pedreira, a classificação automática utilizou 19.911 polígonos. Como o segmentador avalia os níveis de cinza das imagens para gerar os objetos, era previsível que classes semelhantes, e em contato, fossem generalizadas.

A área total analisada (Tabela 5) foi um pouco superior ao perímetro da APA Morro da Pedreira porque os polígonos muito próximos à delimitação do perímetro abrangiam áreas além do recorte e acabaram sendo mantidos, mas isto não influenciou o resultado da classificação (Figura8).

### 4.2 Classificação Automática

A taxa de erro estimada para a classificação automática utilizando o algoritmo *Random Forests* (Out-of-Bag estimate of error rate) foi relativamente alta, de 38,8%. Portanto, a correção manual do mapeamento demandou um tempo elevado, de aproximadamente três semanas.

Os cruzamentos na matriz de confusão (Tabela 4) demonstram entre quais classes ocorreu maior dificuldade de diferenciação e aquelas com maiores acertos. Notamos que existe um padrão de confusão. As classes de vegetação arbórea, Floresta Estacional, Mata Ciliar e Mata Seca/Cerradão tiveram maiores valores de erro entre si. E as classes de vegetação herbácea e arbustiva, Campo Limpo e Afloramento, também demonstraram erros entre si. Incluem-se como exceção o Cerrado/Campo sujo, que é arbóreo, e Rocha Exposta, classe sem vegetação, que apresentaram erros entre Campo Limpo e Afloramento. Tais incorreções são esperadas, devido a semelhança das classes, que têm respostas espectrais parecidas. Cabe ainda citar Solo Exposto, em que a classificação errada como Campo Limpo tem quase a mesma quantidade do número de acertos. E a água, que foi a classe melhor predita.

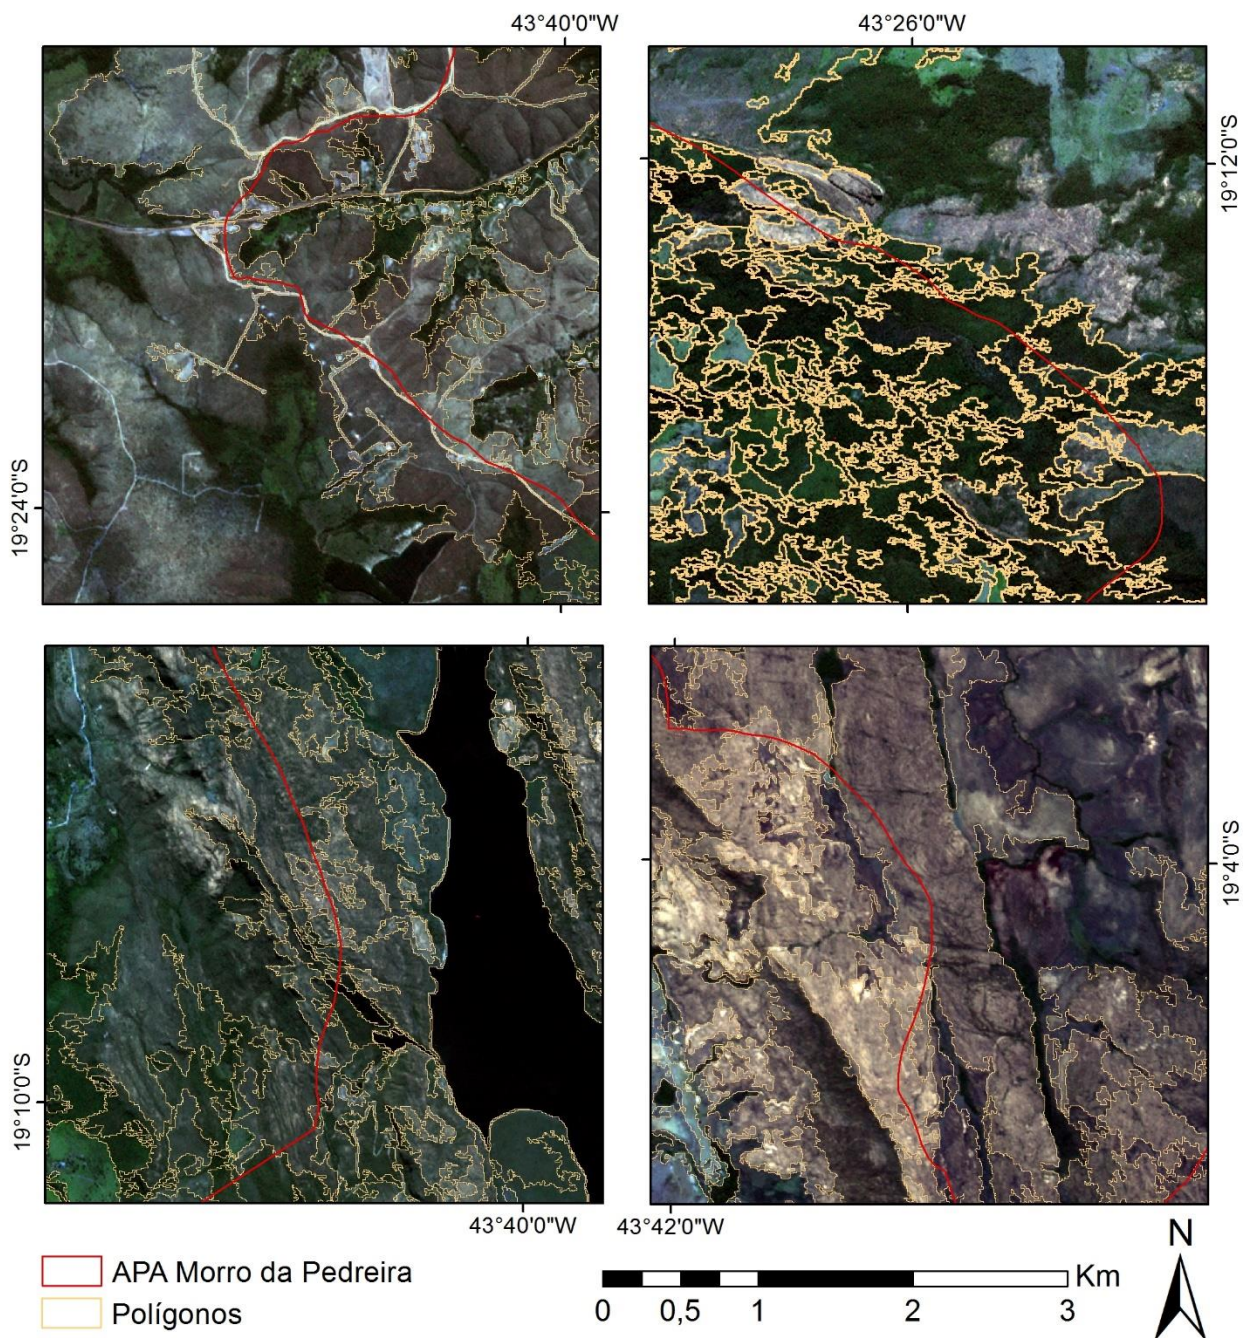


Figura 8 – Exemplos de segmentos (objetos) sobrepostos às imagens *RapidEye*, bem como aos limites da APA Morro da Pedreira. Composição colorida das imagens pelas bandas R1G2B3. Fonte: Elaborado pelo autor.

A análise da acurácia global mostrou que algumas classes tiveram valores consideravelmente elevados, como Cerrado/Campo Sujo, Mata Seca/Cerradão, Solo Exposto e

Afloramento. Isto indica que o teste OOB não foi capaz de prever com exatidão o resultado da classificação. Isto se deve a dois fatores principais; a segmentação não conseguiu gerar os polígonos com tanta precisão, e algumas classes foram sub amostradas pelas amostras de treinamento. Tomando a classe Floresta Estacional como exemplo, vemos que das 175 amostras utilizadas para o teste OOB, 141 corresponderam corretamente à esta classe (acurácia de 80.6%). A maior confusão se deu, como esperado com outras classes que compreendem fisionomias florestais, como a Mata Ciliar. O mesmo pode ser identificado para o restante das classes. Portanto, por essa análise, percebemos que algumas classes tiveram taxas de erro grandes, como Cerrado (86%), Mata Seca/Cerradão (68%), Solo Exposto (59%), Afloramento rochoso (51%), Campo Limpo (30%), Mata Ciliar (31%) e Rocha Exposta (27%). Sendo apenas Floresta Estacional (19%) e Água (14%) com taxas mais baixas.

Tabela 3 – Resultado da classificação automática pelo algoritmo RandomForest e após a correção manual. Área das classes em hectare (ha) e as respectivas porcentagens de cobertura do solo. A coluna com a diferença (%) representa quanto variaram as áreas das classes na classificação pelo algoritmo RandomForest em relação à correção manual.

<b>Classe</b>	<b>Área RF</b>	<b>% RF</b>	<b>Área Manual</b>	<b>%</b>	<b>Diferença</b>
Afloramento	35.554,67	23,97	34.020,69	22,94	4,51
Campo Limpo	32.652,67	22,02	29.486,05	19,88	10,74
Floresta Estacional	23.953,62	16,15	26.335,19	17,76	-9,04
Solo Exposto	18.480,98	12,46	2.023,56	1,36	-813,29
Mata Seca/Cerradão	15.410,36	10,39	12.998,19	8,76	18,56
Cerrado/Campo Sujo	9.863,42	6,65	11.461,17	7,73	-13,94
Mata Ciliar	7.282,39	4,91	7.174,35	4,84	1,51
Água	1.873,32	1,26	1.327,38	0,89	41,13
Urbano	1.736,97	1,17	1.066,72	0,72	62,83
Rocha Exposta	1.494,47	1,01	22.408,87	15,11	-93,33
<b>Total</b>	<b>148.302,87</b>	<b>100</b>	<b>148.302,17</b>	<b>100</b>	

Fonte: Elaborado pelo autor.

### 4.3 Classificação automática e correção manual

Apesar da alta estimativa de erro, o algoritmo apresentou um desempenho interessante para algumas classes. A Tabela 3 expõe os resultados de área para cada classe após a classificação automática pelo algoritmo *RandomForest* e correção manual. As três classes que compõem a maior proporção no território seguiram a mesma ordem, variando no máximo cerca de 10% entre cada mapa. Assim, percebemos predominância de Afloramento Rochoso, Campo Limpo e Floresta Estacional, com 23,97%, 22,02% e 16,15% na classificação pelo *RandomForest*, e 22,94%, 19,88% e 17,76%, respectivamente. Mata Ciliar foi a classe melhor identificada pelo algoritmo, variando apenas 1,51%. Por outro lado, a proporção de Rocha Exposta, Água, Urbano e, principalmente, Solo Exposto foram mal estimadas pelo classificador, alcançando até 813,29% de variação. A classificação pelo algoritmo sub e sobre estimou as áreas, o que demonstra a dificuldade em identificar corretamente as classes, quer seja por falta de amostras de treinamento para algumas classes, ou pela resposta espectral que gerou confusões. Por ser uma região montanhosa, com uma variedade grande de formas do relevo, muitas sombras aparecem nas imagens de satélite. Este fator gerou especial confusão ao algoritmo para definir as áreas de Afloramento, Floresta Estacional, Mata Seca/Cerradão e Rocha Exposta, sendo definidas como Água, que costuma aparecer como manchas escuras, devido a resposta deste elemento aos satélites de sensoriamento remoto.

Tabela 4 – Matriz de confusão gerada para a classificação automática. As linhas correspondem a classe real e as colunas a classe predita. F. E = Floresta Estacional; M. C = Mata Ciliar; M. S./C = Mata Seca/Cerradão; C./C. S = Cerrado/Campo Sujo; Afl = Afloramento Rochoso; C. L = Campo Limpo; A = Água; R. E = Rocha Exposta; S. E = Solo Exposto; Urb = Urbano; A. G. = Acurácia Global (%).

	<b>F. E</b>	<b>M. C</b>	<b>M. S./C</b>	<b>C./C. S</b>	<b>Afl</b>	<b>C. L</b>	<b>A</b>	<b>R. E</b>	<b>S. E</b>	<b>Urb</b>	<b>A. G.</b>
<b>F. E</b>	<b>141</b>	13	13	1	0	1	4	0	0	2	0.19
<b>M. C</b>	21	<b>87</b>	11	1	0	2	4	0	0	1	0.31
<b>M. S./C</b>	29	28	<b>38</b>	6	7	7	1	1	0	2	0.68
<b>C./C. S</b>	2	5	9	<b>13</b>	24	27	0	4	5	3	0.86
<b>Afl</b>	1	3	4	7	<b>70</b>	38	1	18	1	0	0.51
<b>C. L</b>	3	3	3	7	28	<b>166</b>	1	19	6	0	0.30
<b>A</b>	0	1	1	0	0	0	<b>44</b>	0	3	2	0.14

	F. E	M.C	M. S./C	C./C. S	Afl	C. L	A	R. E	S. E	Urb	A. G.
<b>R. E</b>	1	0	1	0	26	15	0	<b>127</b>	3	1	0.27
<b>S. E</b>	0	0	0	2	0	25	0	5	<b>27</b>	7	0.59
<b>Urb</b>	0	1	0	1	0	3	0	2	6	<b>49</b>	0.21

Fonte: Elaborado pelo autor.

A distribuição das classes de vegetação e cobertura do solo se deu de forma semelhante, ao analisar visualmente os mapas gerados (Figura 9 e 10). Nos dois casos se percebe a concentração de Floresta Estacional na faixa Leste, o que se propõe ser relacionado com a umidade mais alta que no restante da área. A Oeste vemos com maior destaque vegetações arbóreas mais secas, como o Cerrado/Campo Sujo e Mata Seca/Cerradão. A região central corresponde exatamente ao Sul da cadeia montanhosa do Espinhaço, a Serra do Cipó, onde ocorrem predominantemente as classes de vegetação arbustiva e herbácea, Campo Limpo e Afloramento Rochoso, e a ausência de vegetação, com Rocha Exposta. O restante das classes ocorre de forma dispersa pela paisagem. As áreas urbanas ocorrem principalmente nas porções mais baixas e planas por facilidade de ocupação, contudo é possível identificar rodovias e estradas pavimentadas, que foram definidas nesta classe, aparecendo espaçadamente ao longo da Serra. Água e Solo Exposto abrangem áreas pequenas nos mapas. As estradas e vias não asfaltadas foram definidas como Solo Exposto, e também aparecem por toda paisagem. Na figura 7 é perceptível a uma quebra vertical na emenda das imagens. Esta diferença clara entre as imagens demonstra como algoritmo não conseguiu distinguir as classes com tanta exatidão. Mesmo com correção atmosférica, as imagens possuem respostas espectrais eventualmente diferentes, gerando tais erros.

As etapas do processo de classificação automática e posterior correção manual estão ilustradas na Figura 11. Esta representa apenas uma parte da área do estudo, aproximada à escala 1:24.000. É notável a qualidade dos resultados dos processamentos automatizados (Figura 11a e 11b), tanto na identificação dos objetos quanto da definição das classes. Contudo, ao comparar as figuras 11b e 11c, ficam evidentes alguns erros do algoritmo.

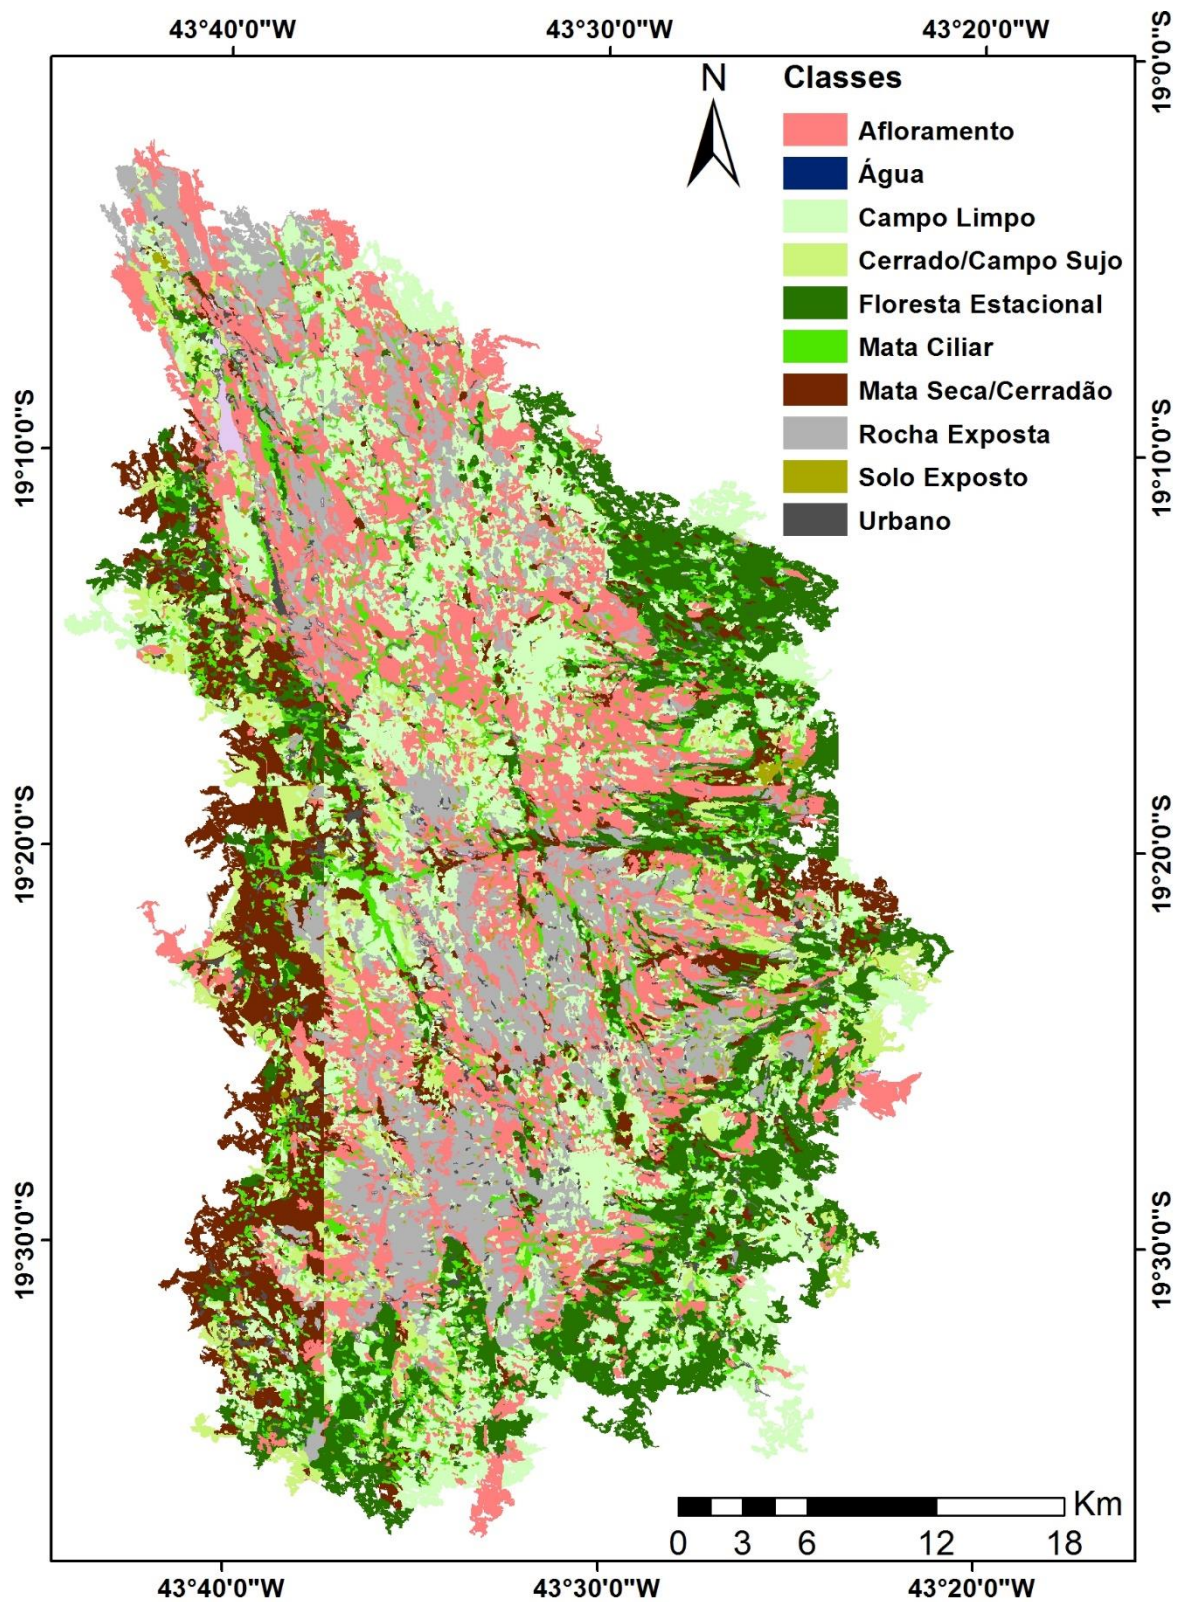


Figura 9 – Mapa com as classes de vegetação e cobertura do solo gerado pelo algoritmo *Random Forests*. Fonte: Elaborado pelo autor.

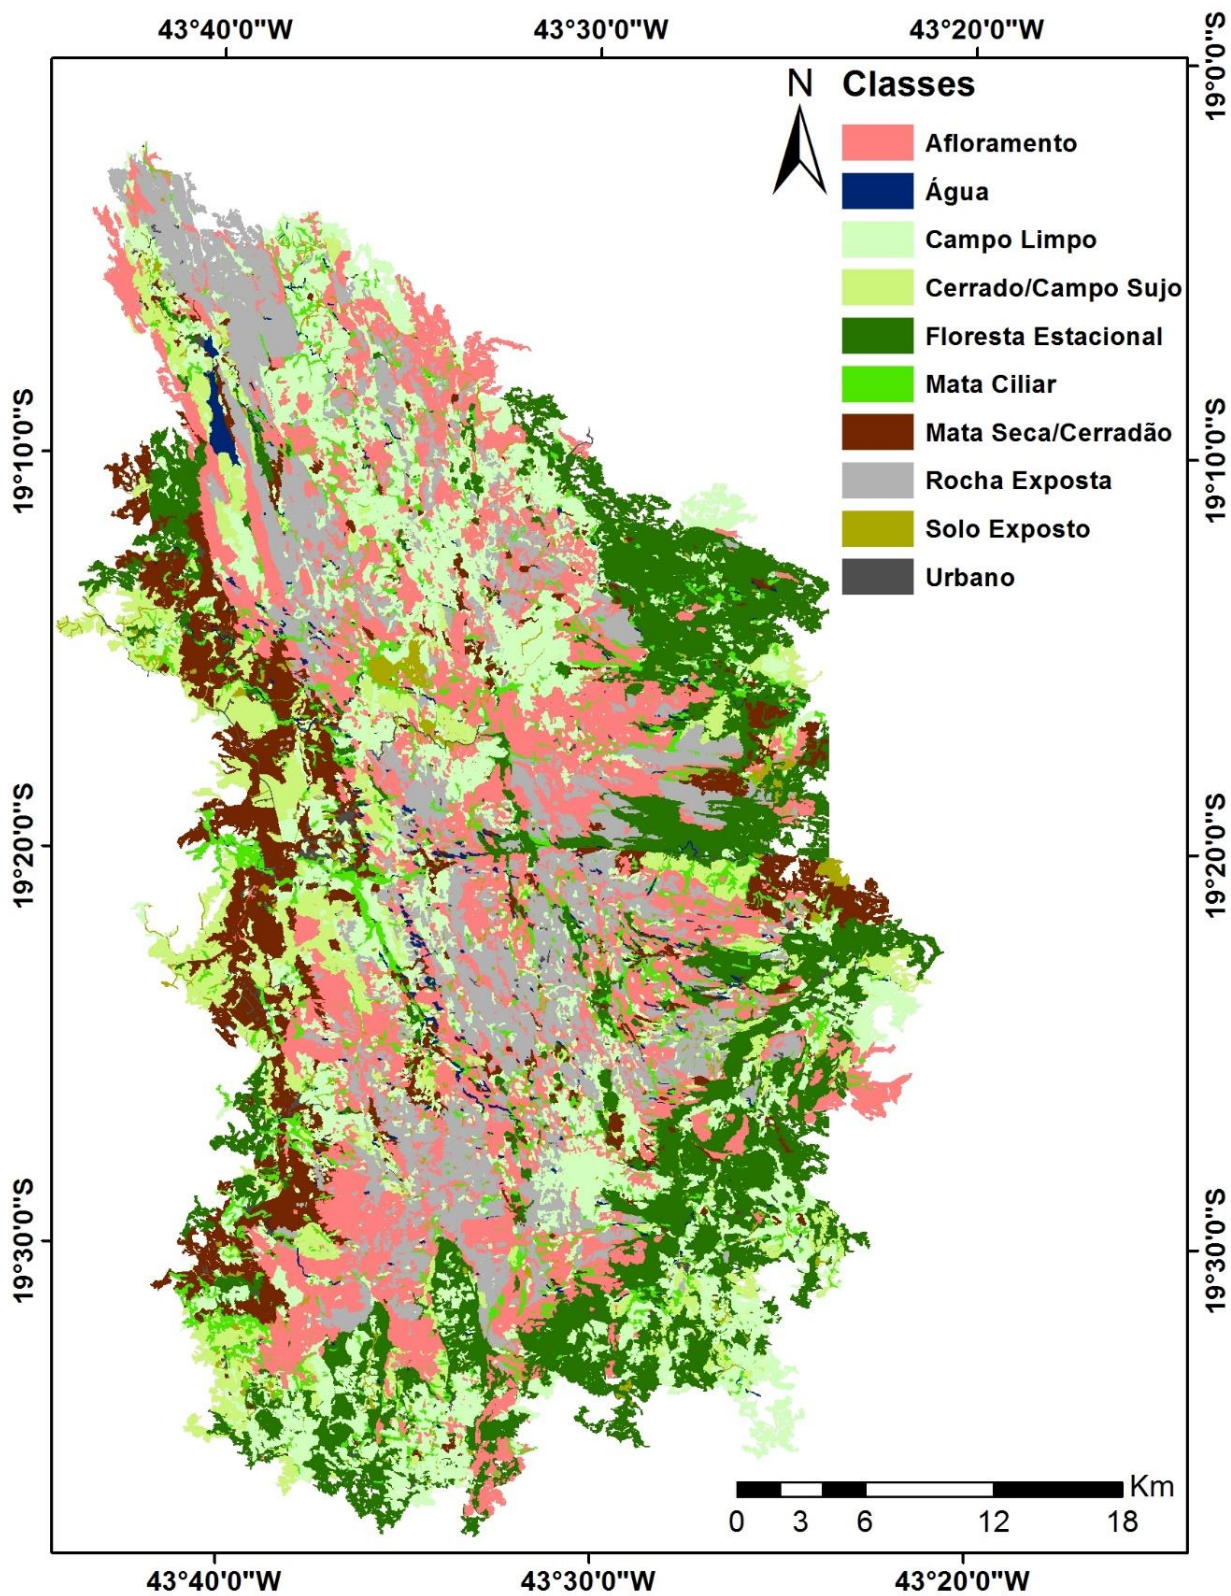


Figura 10 – Mapa com as classes de vegetação e cobertura do solo resultante da correção manual. Fonte: Elaborado pelo autor.

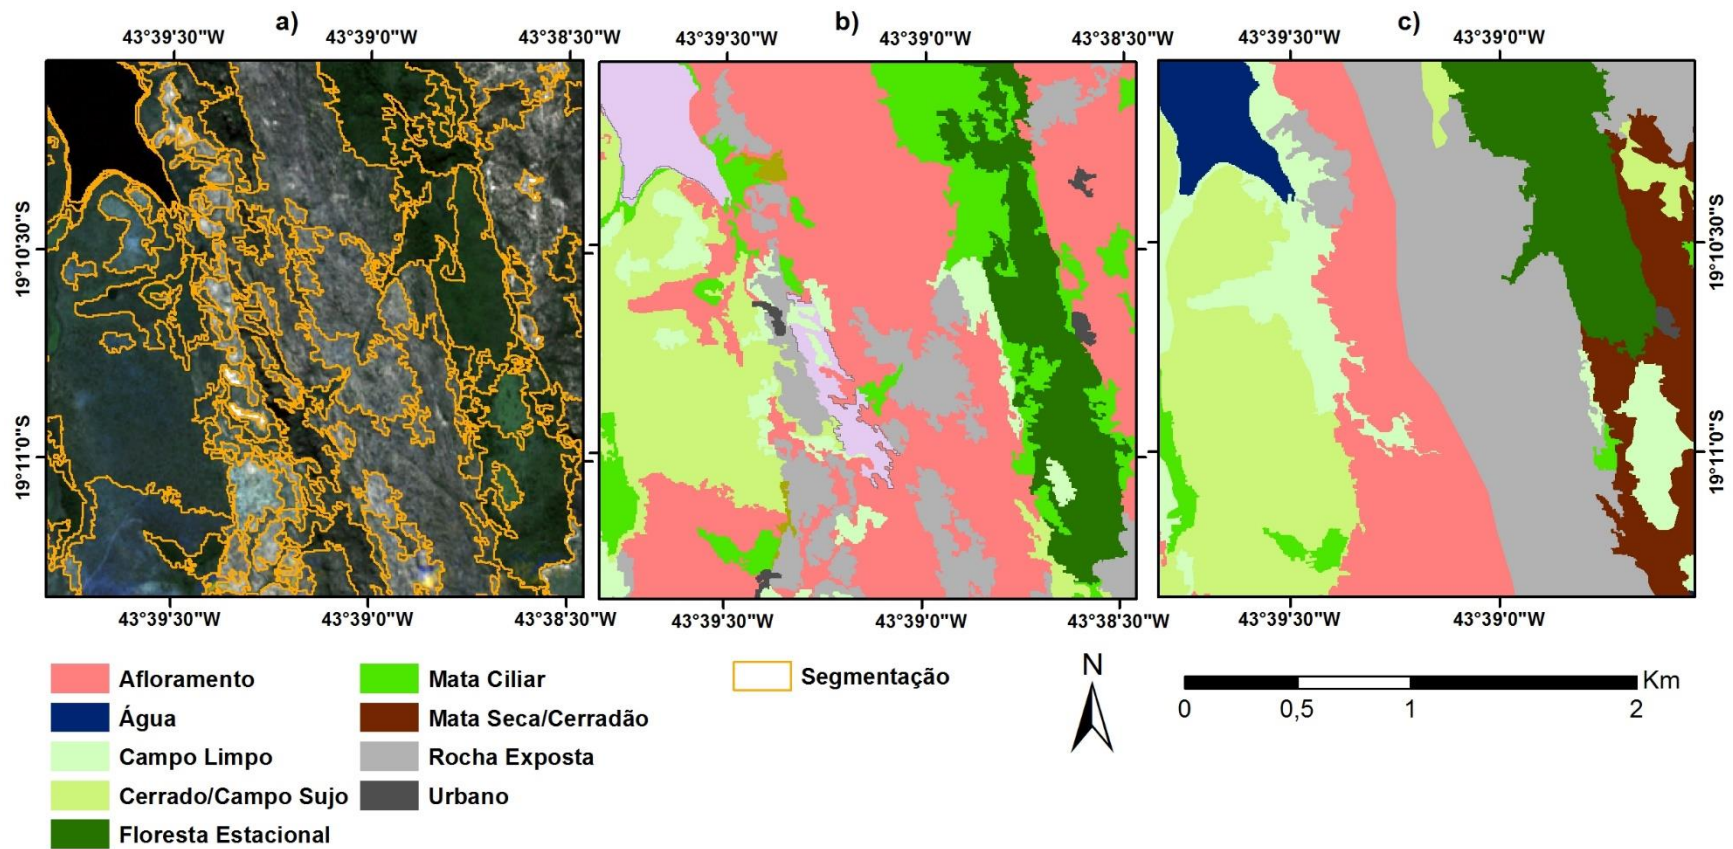


Figura 11 - Etapas do processo do mapeamento: a) Segmentação automática pelo Software *Autoclass*; b) Classificação automática pelo algoritmo *RandomForest*; c) Correção manual da segmentação e classificação da vegetação e cobertura do solo.

Fonte: Elaborado pelo autor.

#### 4.4 Morfometria do relevo.

A morfologia do relevo foi analisada através de três parâmetros, altitude, declividade e orientação das vertentes (Figuras 16, 17 e 18, respectivamente). As classes de vegetação e cobertura do solo apresentaram respostas variadas para cada parâmetro.

No total, a altitude variou 1155 metros, entre 517 e 1672 metros. O gráfico de *boxplot* (Figura 12) indica que existe relação entre cobertura da terra e morfometria do terreno. A classe água encontra-se da menor altitude até 1500 metros, mas predominando de 900 a 1150. Estes valores demonstram o que realmente ocorre, os rios encontram-se nas vertentes, a alturas médias. Já o Afloramento Rochoso é observado com 75% acima dos 1100 metros, alcançando até 1672 metros. Esta classe também respondeu bem a este parâmetro, pois espera-se que aflorem a maiores alturas. Campo Limpo abrange toda a variação altimétrica, predominando entre 900 e 1300 metros. Para esta classe talvez fosse esperado que ocorresse até quase a altura máxima analisada. Cerrado/Campo Sujo foi outra classe que correspondeu a altimetria, variando 1000 metros, mas prevalecendo entre 850 e 1000 metros. Floresta Estacional e Mata Ciliar têm respostas semelhantes à altitude, sendo encontradas em todos os níveis, mas metade de suas ocorrências se dão de 800 a 1150 e 1250, respectivamente. A Mata Ciliar e a Água seguem um padrão parecido, mas com variação mais ampla da mata, por ser mais fácil de identificar nas imagens, pois, por vezes, os corpos d'água possuem poucos metros de largura e não são classificados. A Mata Seca/Cerradão tem a menor abrangência em altitude, com metade da ocorrência entre 800 e 950 metros. A classe Rocha Exposta só é encontrada acima dos 1000 metros, preponderando acima de 1250 metros, o que é realmente esperado por compor os topos de morros. De forma oposta temos as áreas urbanas, em que mais de três quartos são encontradas abaixo dos 1000 metros. A classe de Solo varia em todas as alturas, concentrando-se de 825 a 1200 metros.




Figura 12 – Boxplot da variação de altitude, em metros, para cada classe de vegetação e cobertura do solo. Fonte: Elaborado pelo autor.

Quanto à declividade, a variação foi menos significativa, e nem todas as classes apresentam uma relação satisfatória (Figura 14). As classes foram encontradas de 0 a 18% de declividade, o que, de acordo com a proposta da EMBRAPA (1979, apud FREIRE, LAFE e Christófar, 2013) variam de plano (0-3%), passando por suave (3-8%), até ondulado (8-20%). Todas estão dispostas em superfícies planas. Classes como Urbano, Campo Limpo e mesmo Mata Ciliar, corresponderam ao esperado, sendo encontradas com declividades menores, relevo ondulado com até 15%. As classes do Cerrado/Campo Sujo Mata Seca/Cerradão e Rocha Exposta responderam de forma muito semelhante, não ultrapassando os 15%, e com metade da ocorrência entre 2,5 e 7,5%. Isto é interessante, pois realmente se espera que a vegetação arbórea não ocorra em ambientes muito declivosos, e as rochas ficam aparentes nos topos, mais planos. Já Afloramento e Floresta Estacional possuem as maiores variações, o que é estranho para a última, apesar de não chegar a 20% de declividade. O Solo Exposto também ocorreu em áreas planas a suaves, principalmente por ser composto, no estudo, de estradas não asfaltadas. A classe Água não aparece neste gráfico pois sua variação foi muito grande, indicando que, provavelmente, muitas áreas sombreadas foram

identificadas erroneamente como água.

Em relação à orientação da vertente, todas as classes estão dispostas em todas as direções, ou seja, encontram-se variando de 0 a 360°, como é perceptível no boxplot em questão (Figura 15). Mas é notável que todas possuem metade de seus valores ao menos entre 60 e 280 graus, de Nordeste a Oeste. Em algumas situações existem uma orientação mais restrita. São os casos de Floresta estacional, que se concentra de 100 a 230 graus (Leste, Sudeste e Sul), e Mata Ciliar, variando entre 100 e 250 graus (Leste, Sudeste, Sul e Sudoeste). As demais classes apresentam orientações variando mais de 180 graus, mas mesmo assim no encontrando-se no eixo Leste-Oeste. A Água novamente não foi representada, pois os erros com o sombreamento impediram analisá-la.

Portanto, podemos definir as classes de acordo com o relevo da seguinte forma (Figura 13):

Afloramento Rochoso	Predomina acima de 1000 metros, relevo plano a ondulado, e vertentes Leste-Oeste
Água	Predomina em alturas médias, não foi possível definir declividade e orientação de vertente
Campo Limpo	Predomina entre 900-1300 metros, com relevo plano a suave, e vertentes Leste-Oeste
Cerrado/Campo Sujo	Predomina em alturas médias, relevo plano a suave, e vertentes Leste-Oeste
Floresta Estacional	Predomina em alturas médias, relevo plano a ondulado, e vertentes Leste Sudoeste
Mata Ciliar	Predomina entre 800-1250 metros, com relevo plano a suave, e vertentes Leste-Sudoeste
Mata Seca/Cerradão	Predomina abaixo dos 1000 metros, com relevo plano a suave, e vertentes Leste-Oeste
Rocha Exposta	Encontra-se somente acima de 1000 metros, relevo plano a suave, e vertentes Nordeste-Oeste
Solo Exposto	Predomina entre 825 a 1200 metros, com relevo plano a suave, e vertentes Leste-Oeste
Urbano	Abaixo de 1000 metros, relevo plano a suave, e vertentes Leste-Oeste

Figura 13 – Quadro com a relação das classes de vegetação e cobertura do solo com características do relevo.




Figura 14 - Boxplot da variação de declividade, em porcentagem, para cada classe de vegetação e cobertura do solo. Fonte: Elaborado pelo autor.




Figura 15 – Boxplot da variação da orientação das vertentes, em graus, para cada classe de vegetação e cobertura do solo. Fonte: Elaborado pelo autor.

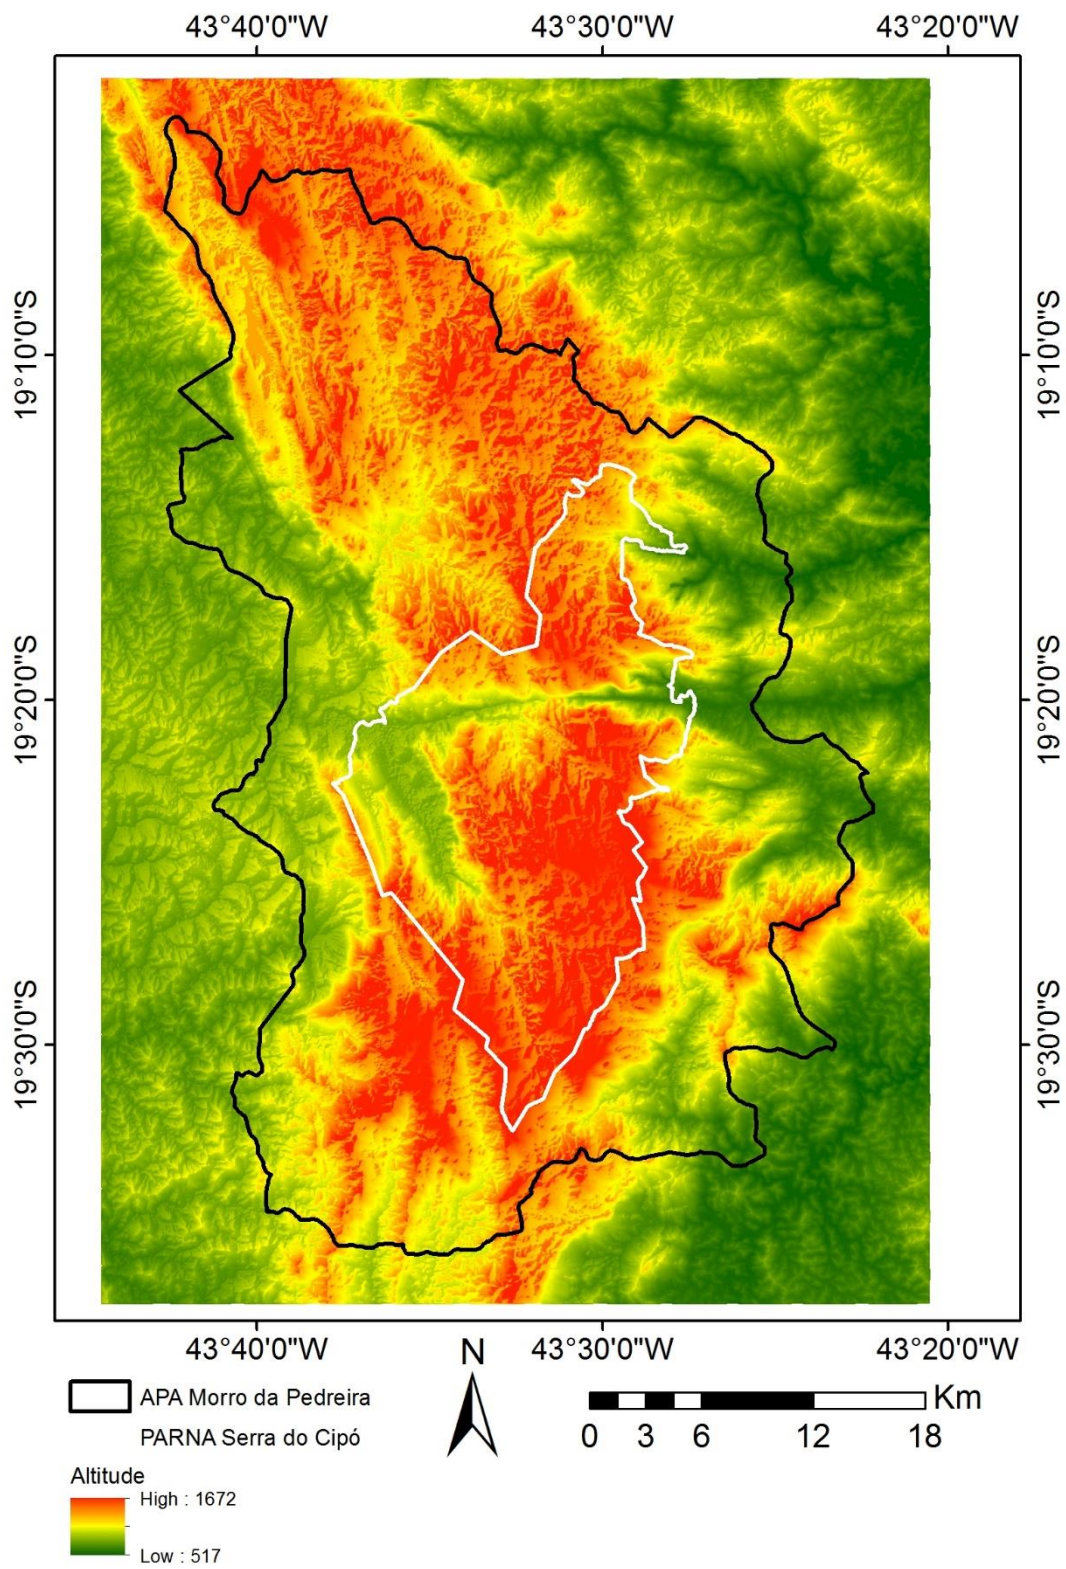


Figura 16 – Mapa de altitude, em metros. Fonte: Elaborado pelo autor.




Figura 17 – Mapa de declividade, em porcentagem. Fonte: Elaborado pelo autor.




Figura 18 – Mapa de orientação de vertente, em graus. Fonte: Elaborado pelo autor.

#### 4.5 Geodiversidade

O mapa de geodiversidade de Minas Gerais, no recorte para a região da APA Morro da Pedreira (Figura 19) possui claramente uma classe predominante no embasamento e uma segunda com certo destaque pelas proporções em área (Tabela 5). São elas do Domínio das sequências sedimentares proterozóicas dobradas, metamorfizadas de baixo a médio grau, composto por metarenitos, quartzitos e metaconglomerados, com relevo montanhoso (legenda 6); e a outra composta por intercalações irregulares de metassedimentos arenosos e siltico-argilosos, também de relevo montanhoso (legenda 9) (ver Figura 7). O predomínio se mantém mesmo se utilizarmos a escala apenas da Unidade geológico-ambiental, sem o relevo, na qual temos nove classes. A soma das áreas das classes na mesma Unidade não altera a ordem de ocupação no embasamento.

A distribuição da vegetação e classes de cobertura do solo de acordo com a diversidade de estruturas do relevo e litografia está exposta na Tabela 6. Apesar de uma única classe da Geodiversidade corresponder a quase 60% da área, as classes de vegetação estão melhor distribuídas nas classes 3, 9, 10 e 12 (DCGMGLgno/R4b, DSP1sac/R4b, DSP1sac/R4c e DSP2mcsaa/R4c, respectivamente), que com as áreas somadas atingem apenas 22,15%. A vegetação está distribuída de forma irregular, mas são as classes mais representadas em todas as categorias da Geodiversidade. Notamos que o Afloramento possui uma relação mais direta com a categoria 14 (DSP2mqmtc/R4c). A categoria 5 está sobrestimada, devido sua proporção pequena na área.

A escolha pelas classes de vegetação e cobertura do solo pretendeu abranger a heterogeneidade da paisagem. Se podemos falar que as classes de fisionomias de vegetação utilizadas representam bem a diversidade biológica presente na região do estudo, então temos uma representação interessante dos aspectos considerados na análise de geodiversidade quanto aos tipos de vegetação. As seis classes de vegetação são recorrentes em pelo menos três categorias de geodiversidade. Porém, quatro classes, Campo Limpo, Cerrado/Campo Sujo, Floresta Estacional e Mata Seca/Cerradão, são bem representadas numa diversidade grande de Unidades geológico-ambientais. Ao avaliar a tabela 6, notamos que estas quatro classes de vegetação correspondem a pelo menos 10% da área de 14, 8, 13 e 9 categorias do mapa de geodiversidade, respectivamente.

Tabela 5 – Resultado das áreas, em hectare e porcentagem, das classes que representam a

geodiversidade nos limites da APA Morro da Pedreira. GEO\_REL: código das Unidades geológico-ambientais somadas às classes de relevo.

<b>Legenda</b>	<b>GEO_REL</b>	<b>Área (ha)</b>	<b>%</b>
6	DSP2mqmtc/R4c	88.209	59,62
9	DSP2msa/R4c	22.031	14,89
15	DCGMGLgno/R4c	9.094	6,15
12	DSP2mcsaa/R4a1	6.444	4,36
04	DSP1sac/R4a2	4.269	2,89
10	DSP2sag/R4c	3.628	2,45
08	DSP2mqsafmg/R4c	2.539	1,72
11	DSP2mcsaa/R4c	2.080	1,41
13	DCMUbU/R4c	2.026	1,37
17	DCGMGLgno/R4b	1.942	1,31
05	DSP1sac/R4a1	1.729	1,17
16	DCGMGLgno/R4a2	1.376	0,93
01	DCa/R1a	706	0,48
03	DSP1sac/R4b	660	0,45
02	DSP1sac/R4c	623	0,42
07	DSP2mqmtc/R4b	588	0,40
14	DCMUbU/R4a2	12	0,01
<b>Total</b>		<b>147.956</b>	<b>100</b>

Fonte: Elaborado pelo autor.

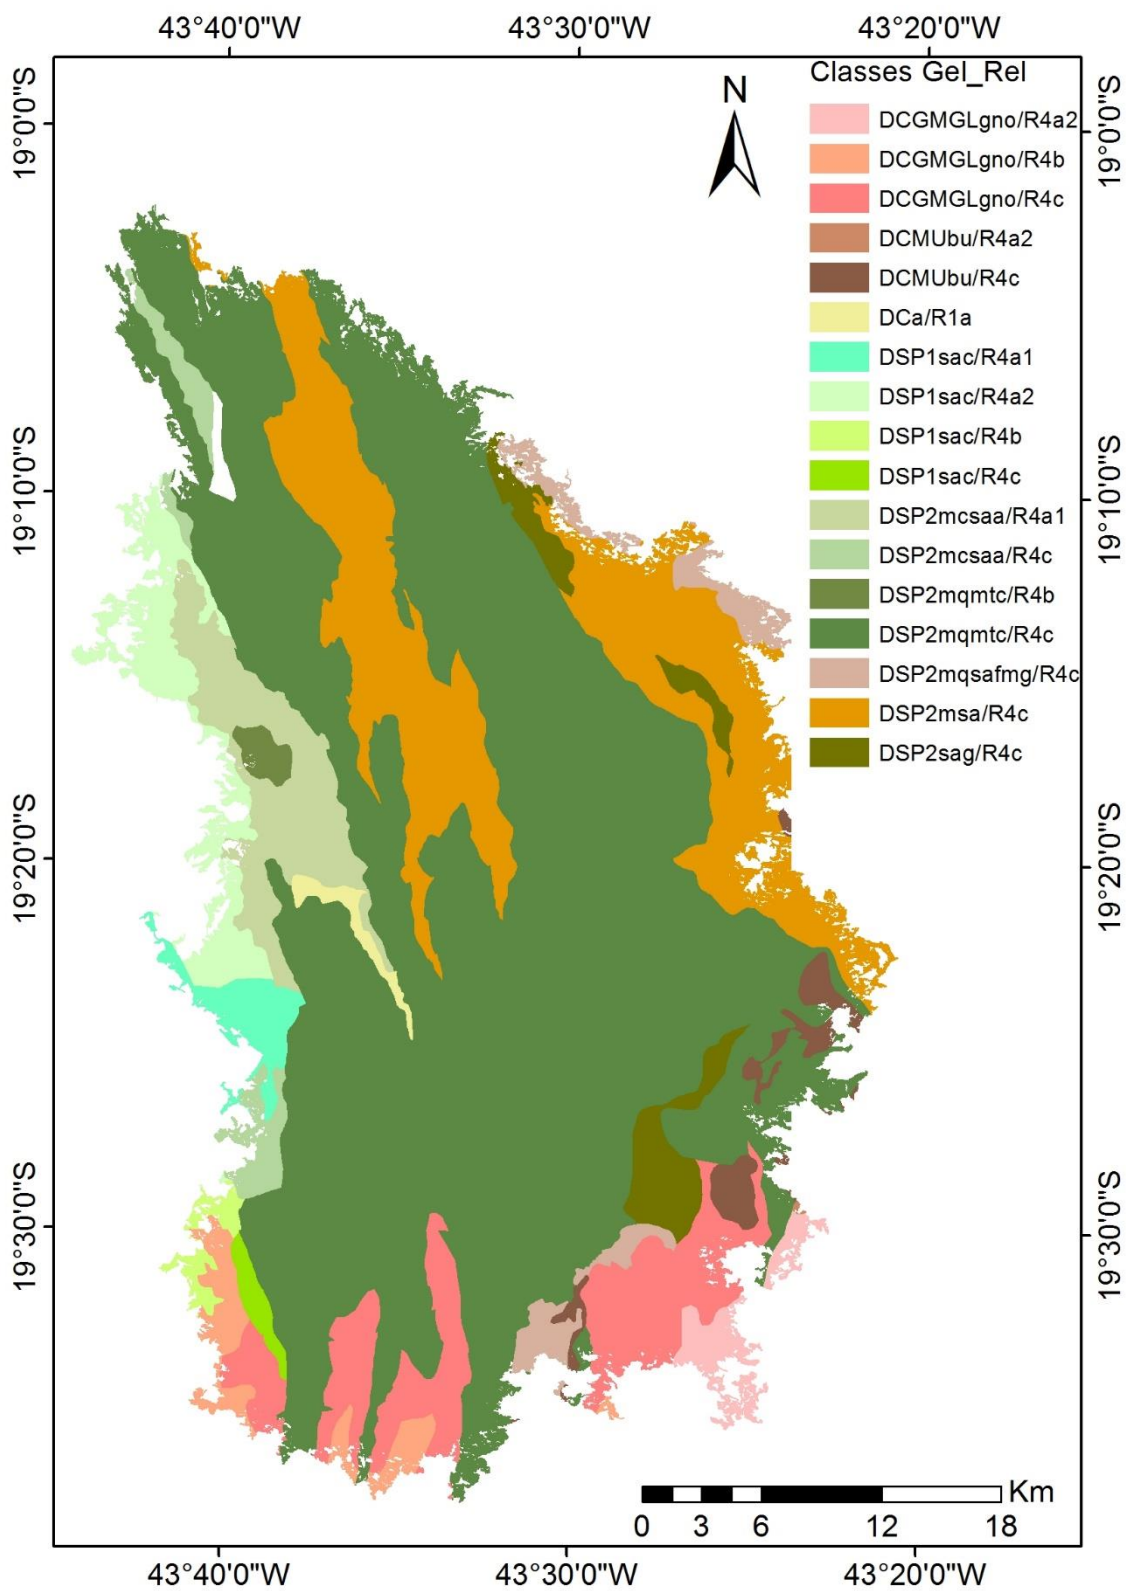


Figura 19 – Mapa de Geodiversidade que sintetiza o conjunto das Unidades geológico-ambientais e categorias do relevo. Fonte: Elaborado pelo autor.

Tabela 6 - Proporção, de área em porcentagem, de cada classe de vegetação e cobertura do solo que compõe cada Unidade geológico-ambiental + relevo do mapa de Geodiversidade. Afl = Afloramento Rochoso; A = Água; C. L = Campo Limpo; C./C. S = Cerrado/Campo Sujo; F. E = Floresta Estacional; M. C = Mata Ciliar; M. S./C = Mata Seca/Cerradão; R. E = Rocha Exposta; S. E = Solo Exposto; Urb = Urbano.

<b>Legenda</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>	<b>7</b>	<b>8</b>	<b>9</b>	<b>10</b>	<b>11</b>	<b>12</b>	<b>13</b>	<b>14</b>	<b>15</b>	<b>16</b>	<b>17</b>
Afl.	1,9	0,2	0,1	2,0	0,0	4,1	3,0	0,5	0,0	<b>14,5</b>	0,7	1,5	0,0	<b>33,5</b>	6,5	<b>16,4</b>	4,2
A.	3,9	1,0	0,0	0,2	0,0	0,4	0,0	0,1	0,0	0,0	1,2	0,7	0,0	0,9	0,1	0,7	0,4
C. L.	<b>44,0</b>	<b>59,0</b>	<b>27,3</b>	<b>36,5</b>	0,0	<b>44,1</b>	<b>11,3</b>	5,9	<b>13,7</b>	<b>19,5</b>	<b>14,3</b>	<b>25,3</b>	0,5	<b>15,7</b>	<b>16,4</b>	<b>28,0</b>	<b>29,9</b>
C./C. S.	1,3	<b>9,8</b>	<b>23,6</b>	9,2	7,4	5,6	<b>32,5</b>	<b>36,6</b>	8,0	<b>14,8</b>	<b>16,1</b>	<b>17,9</b>	<b>43,8</b>	5,6	0,0	3,9	2,4
F. E.	5,2	<b>24,4</b>	<b>24,4</b>	<b>44,7</b>	<b>92,6</b>	<b>41,5</b>	2,8	<b>14,2</b>	<b>10,5</b>	<b>11,0</b>	3,6	<b>28,6</b>	0,0	<b>10,5</b>	<b>73,9</b>	<b>26,6</b>	<b>53,2</b>
M. C.	<b>25,3</b>	4,2	7,9	3,6	0,0	2,8	6,5	5,1	<b>16,8</b>	<b>15,3</b>	8,0	7,5	1,5	4,1	0,8	6,5	3,1
M. S./C.	<b>16,7</b>	0,0	<b>12,2</b>	0,6	0,0	0,4	<b>37,5</b>	<b>33,5</b>	<b>49,7</b>	<b>22,2</b>	<b>49,7</b>	<b>13,1</b>	<b>52,3</b>	5,1	0,3	7,1	4,4
R. E.	0,0	0,0	0,0	0,5	0,0	0,0	0,2	0,1	0,0	0,0	0,1	0,6	0,5	23,5	1,3	7,0	0,8
S. E.	0,4	1,4	3,3	1,8	0,0	0,7	2,7	2,6	0,9	1,7	2,1	2,3	0,5	0,7	0,3	3,3	0,8
U.	1,3	0,1	1,3	0,8	0,0	0,5	3,6	1,5	0,4	1,1	4,2	2,6	0,9	0,4	0,4	0,5	0,8
	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100

Fonte: Elaborado pelo autor.

## 5. CONCLUSÃO

Buscamos compreender como variáveis físicas que compõem o relevo, correspondendo ao conceito de Geodiversidade, influenciam a ocorrência e distribuição de fisionomias de vegetação na região da Serra do Cipó, MG, e assim tentar auxiliar futuros estudos e a conservação da natureza, ao também considerar estes conceitos em planejamentos e pesquisas.

Na primeira parte deste trabalho foi realizado um mapeamento semi-automático das classes de vegetação e cobertura do solo. O mapeamento contribuiu ao reconhecer padrões da paisagem nas imagens que, mesmo com a alta resolução, podem ser de difícil caracterização. Apesar de, para algumas classes, a classificação automática ter realizado uma boa identificação, de modo geral não foi possível obter-se a precisão desejada, com um resultado final de mais de um terço de erro, e algumas classes individualmente atingindo até 86% de erro. Sugerimos que isto se deve à necessidade de melhoria no processo de segmentação, e à variação no número de amostras de treinamento, utilizadas no processamento do algoritmo *RandomForest*. A segmentação é um momento inicial e muito importante nesta metodologia, garantindo a qualidade de todo o processo restante, e avaliamos que a segmentação não foi suficientemente precisa. Em muitos momentos notamos que polígonos não representavam bem os objetos da paisagem, ou apenas em parte, abrangendo elementos que deveriam compor outras classes. Quanto a amostragem para treinar o classificador, esta demonstra ter sido insuficiente para algumas classes, ocasionando confusões de classificação. Entendemos que estes problemas fazem parte do desenvolvimento da pesquisa, e podem ser melhor explorados. A segmentação requer mais testes para aprimorar a definição dos polígonos. Também é importante ressaltar que o número de classes foi elevado. Assim, algumas apresentam respostas espectrais similares, gerando erros tanto na segmentação quanto na classificação. Vemos, portanto algumas possibilidades para aprimorar esta etapa: utilizar uma quantidade menor de classes em uma primeira classificação, refinando o mapeamento a cada etapa; fazer mais testes com o tamanho mínimo dos polígonos (*minsize* no software *Autoclass*) e com o número de classes no segmentador; ainda é possível fazer uma análise refinada das imagens segmentadas, antes de iniciar a classificação automática.

A segunda etapa buscou analisar a relação entre a geodiversidade e a biodiversidade da Serra do Cipó. Foi possível reconhecer padrões de relevo e geologia com a distribuição de

fitofisionomias. Como foi apresentado, a região possui relevo e embasamento muito heterogêneos, compondo uma grande variedade de condições que dão suporte para a diversidade de formas de vida. Os tipos de vegetação estudados, com exceção de Afloramento Rochoso e Mata Ciliar, não apresentaram correlações específicas com estas estruturas, o que entendemos como adaptação a esta multiplicidade de condições. A análise da morfometria do relevo revelou uma predominância de todas as classes com a orientação Leste-Oeste das vertentes (apesar de serem localizadas em todas as direções), e um padrão na altimetria condizente com o encontrado na região. Quanto às relações das fitofisionomias com as Unidades Geológico-Ambientais empregadas na análise da Geodiversidade, notamos que Afloramento Rochoso e Mata Ciliar estão diretamente relacionados a apenas três categorias da Geodiversidade, cada uma (10, 14 e 16, e 1, 9 e 10, respectivamente). Porém, as outras classes possuem relações com pelo menos metade das categorias. Deste modo, afirmamos que a manutenção de regiões estruturalmente diversas pode permitir que a biodiversidade seja também assegurada, pensando em uma escala de tempo ecológica.

Não podemos deixar de comentar a importância da escala nos resultados. O mapeamento da CPRM e da vegetação foram realizados em escalas muito distintas. E mesmo a vegetação foi generalizada para alguns tipos fisionômicos que, é claro, não correspondem à ampla diversidade biológica da Serra do Cipó. Poucos mapeamentos geológicos foram feitos, ou estão disponíveis, em escalas maiores, 1:100.000 por exemplo, na região. Assim, é provável que exista uma diversidade de unidades geológico-ambientais mais elevada, reforçando a ideia do cenário da natureza, como um complexo de formas e estruturas que, exatamente em sua diversidade, suporta a variabilidade biótica.

De modo geral todo o desenvolvimento do trabalho foi satisfatório, inclusive por priorizar o uso de softwares livres, como *GeoSetter*, *QGIS* e *R*, e muito novos, como *Autoclass*. Os resultados demonstram que o uso de metodologias automáticas e semi-automáticas são importantes e úteis para agilizar o processamento de imagens de sensoriamento remoto.

Propor uma redefinição na área de uma unidade de conservação exigiria analisar um espectro maior de ambientes, além dos limites definidos para a APA Morro da Pedreira e do PARNA da Serra do Cipó. E esta região já possui uma diversidade muito grande em relação a sua área no território brasileiro. Desta forma, entendemos que estas unidades de conservação contemplam características muito importantes na região, responsáveis por garantir micro habitats

e refúgios, mas que a metodologia pode ser aplicada na elaboração de planejamentos de outras áreas protegidas.

## REFERÊNCIAS

ANDERSON, M. G.; FERREE, C. E. Conserving the stage: Climate change and the Geophysical underpinnings of species diversity. **Plos One**, v. 5, n. 7, p. 1 - 10. 2010.

ANTUNES, M. A. H.; SIQUEIRA, J. C. S. Características das imagens RapidEye para mapeamento e monitoramento agrícola e ambiental. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto**. São José dos Campos: INPE, 2013. p. 547-554.

ARVOR, D.; DURIEUX, L.; ANDRÉS, S.; LAPORTE, M. A. Advances in geographic object-based image analysis with ontologies: A review of main contributions and limitations from a remote sensing perspective. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 82, p. 125-137. 2013.

BEIER, P.; BROST, B. Use of land facets to plan for climate change: Conserving the arenas, not the actors. **Conservation Biology**, v. 24, n. 3, p. 1 - 10. 2010.

BEIER, P.; HUNTER, M. L.; ANDERSON, M. Special section: Conserving nature's stage - Introduction. **Conservation Biology**, v. 29, n. 3, p. 613-617. 2015.

BIVAND, R.; KEITT, T.; ROWLINGSON, B.; PEBESMA, E.; SUMMER, M.; HIJMANS, R.; ROUAULT, R. rgdal: Bindings for the Geospatial Data Abstraction Library. R Package versão 1.1-10. 2016. Disponível em <<http://www.gdal.org/>>. Acesso em: 15 ago 2016.

BLASCHKE, T.; HAY, G. J.; KELLY, M.; et al. Geographic object-based image analysis – Towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180–191, 2014.

BRASIL. **Novo Código Florestal**. Lei nº 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/\\_ato2011-2014/2012/lei/12651.htm](http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/12651.htm)>. Acesso em: 04 mar. 2016.

BRASIL. **Decreto Presidencial**. Decreto nº 7.830, de 17 de outubro de 2012. Dispõe sobre o

Sistema de Cadastro Ambiental Rural, o Cadastro Ambiental Rural, estabelece normas de caráter geral aos Programas de Regularização Ambiental. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/\\_Ato2011-2014/2012/Decreto/D7830.htm](http://www.planalto.gov.br/ccivil_03/_Ato2011-2014/2012/Decreto/D7830.htm)>. Acesso em: 04 mar. 2016.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, p. 5-32. 2001.

CARVALHO, F.; SOUZA, F. A.; CARRENHO, R.; MOREIRA, F. M. S.; JESUS, E. C.; FERNANDES, G. W. The mosaic of habitats in the high-altitude Brazilian rupestrian fields is a hotspot for arbuscular mycorrhizal fungi. **Applied Soil Ecology**, v. 52, p. 9-19. 2012.

CLEVE, C.; KELLY, M.; KEARNS, F. R.; MORITZ, M. Classification of the wildland-urban interface: A comparison of pixel- and object-based classifications using high-resolution aerial photography. **Computers, Environment and Urban Systems**, v. 32, p. 317-326. 2008.

COMER, P. J.; PRESSEY, R. L.; HUNTER, M. L.; SCHLOSS, C. A.; BUTTRICK, S. C.; HELLER, N. E.; TIRPAK, J. M.; FAITH, D. P.; CROSS, M. S.; SHAFFER, M. L. Incorporating geodiversity into conservation decisions. **Conservation Biology**, v. 29, n. 3, p. 692-701. 2015.

DANTAS, G. V. **Utilização de classificador *Random Forest* na detecção de falhas em máquinas rotativas**. 2014. 93 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Eletrônica e Computação) – Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2015.

DOBROWSKI, S. Z. A climatic basis for microrefugia: The influence of terrain on climate. **Global Change Biology**, v. 17, p. 1022-1035. 2011

DRAGUT, L.; BLASCHKE, T. Automated classification of landform elements using object-based image analysis. **Geomorphology**, v. 81, p. 330-344. 2006.

ENVI Atmospheric Correction Module: QUAC and FLAASH User's Guide, 2009, 44 p. Disponível em <[https://www.exelisvis.com/portals/0/pdfs/envi/Flaash\\_Module.pdf](https://www.exelisvis.com/portals/0/pdfs/envi/Flaash_Module.pdf)>. Acesso em 20 dez. 2015.

ECHTERNACHT, L.; TROVÓ, M.; OLIVEIRA, C. T.; PIRANI, J. R. Areas of endemism in the

Espinhaço Range in Minas Gerais, Brazil. **Flora**, v. 206, p. 782-791. 2011.

FREIRE, A. J.; LAGE, G. B.; CHRISTÓFARO, C. Comparação entre parâmetros morfométricos de bacias hidrográficas gerados por dados SRTM e ASTER GDEM: estudo de caso para bacias do Vale do Jequitinhonha-MG. in: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto**. São José dos Campos: INPE, 2013. p. 5443-5450.

GALIANO, V. F. R.; GHIMIRE, B.; ROGAN, J.; OLMO, M. C.; SANCHEZ, J. P. R. An assessment of the effectiveness of a random forest classifier. **ISPR Journal of Photogrammetry and Remote Sensing**, v. 67, p. 93-104. 2012a.

GALIANO, V. F. R.; OLMO, M. C.; HERNANDEZ, F. A.; ATKINSON, P. M.; JEGANATHAN, C. Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. **Remote Sensing Environment**, v. 121, p. 93-107. 2012b.

GRAY, M. **Geodiversity**: Valuing and conserving abiotic nature. Chichester: John Wiley & Sons, Ltd. 2004. 448 p.

GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R.; Random forest for land cover classification. **Pattern Recognition Letters**, v. 27, p. 294-300. 2006.

GONÇALVES, T. S. A floresta estacional decidual no Brasil: Distribuição geográfica e influência dos aspectos pedogeomorfológicos na vegetação. **Revista Monografias Ambientais**, v. 14, n. 1, p. 144-153. 2015.

HAY, G. J.; CASTILLA, G. Geographic object-based image analysis (GEOBIA): A new name for a new discipline. In: BLASCHKE, T.; LANG, S.; HAY, G. **Object-based image analysis: Spatial concepts for knowledge-driven remote sensing applications**. Berlin: Springer, 2008, p. 77.

HIJMANS, R.; ETEN, J. V.; CHENG, J.; MATTIUZZI, M.; SUMMER, M.; GREENBERG, J. A.; LAMIGUEIRO, O. P.; BEVAN, A.; RANCINE, E. B.; SHORTRIDGE, A. raster: Geographic Data Analysis and Modeling. R Package versão 2.5-8. 2016. Disponível em <<http://cran.r-project.org/package=raster>>. Acesso em: 15 ago 2016.

ICMBIO – Instituto Chico Mendes de Conservação da Biodiversidade. **APA Morro da Pedreira**. Disponível em: <<http://www.icmbio.gov.br/portal/biodiversidade/unidades-de-conservacao/biomas-brasileiros/cerrado/unidades-de-conservacao-cerrado/2058-apa-do-morro-da-pedreira.html>>. Acesso em 28 mar. 2016.

INPE – Instituto Nacional de Pesquisas Espaciais. Divisão de Processamento de Imagem. **Introdução ao Sensoriamento Remoto**. 2016. Disponível em: <[http://www.dpi.inpe.br/spring/portugues/tutorial/introducao\\_sen.html](http://www.dpi.inpe.br/spring/portugues/tutorial/introducao_sen.html)>. Acesso em: <1 mai. 2016>.

LAWLER, J. J.; ACKERLY, D. D.; ALBANO, C. M.; ANDERSON, M. G.; DOBROWSKI, S. Z.; GILL, J. L.; HELLER, N. E.; PRESSEY, R. L.; SANDERSON, E. W. WEISS, S. B. The theory behind, and the challenges of, conserving nature's stage in a time of rapid change. **Conservation Biology**, v. 29, n. 3, p. 618-629. 2015.

LIAW, A.; WIENER, M. Classification and regression by randomForest. **R News**, v. 2/3, p. 18-22. 2002.

LIAW, A.; WIENER, M. randomForest. R Package versão. 2015. Disponível em <<https://www.stat.berkeley.edu/~breiman/RandomForests/>>. Acesso em: 15 ago 2016.

MARCHADO, M. F.; SILVA, S. F. **Geodiversidade do Estado de Minas Gerais**: Programa de Geologia do Brasil, Levantamento de Geodiversidade. Belo Horizonte: Serviço Geológico Brasileiro – CPRM. 2010. 131 p.

MAXWELL, A. E.; WARNER, T. A. Differentiating mine-reclaimed grasslands from spectrally similar land cover using terrain variables and object-based machine learning classification. **International Journal of Remote Sensing**, v. 36, n. 17, p. 4384-4410. 2015.

MENESES, P. R.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UNB, 2012. 276 p. Disponível em: <<http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>, acesso em: 27 fev. 2016.

NASA. **Shuttle Radar Topography Mission**: The Mission to Map the World. 2016. Disponível

em:< <http://www2.jpl.nasa.gov/srtm/>>. Acesso em: 05 set. 2016.

PIRANI, J.R.; SANO, P.T.; MELLO-SILVA, R.; MENEZES, N.L.; GIULIETTI, A.M.; ZAPPI, D.C. & Jono, V.Y. Flora da Serra do Cipó, Minas Gerais (2015). Disponível em: <<http://www.ib.usp.br/botanica/serradocipo>>, Acesso em 17 ago. 2016.

OSHIRO, T, M. **Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para a classificação de bases de expressão gênica**. 2013. 101 f. Dissertação (Mestrado em Bioinformática) – Interunidades em Bioinformática, Universidade de São Paulo, Ribeirão Preto, 2013.

REICHE, J.; VERBESSELT, J.; HOEKMAN, D.; HEROLD, M. Fusing Landsat and SAR time series to detect deforestation in the tropics. **Remote Sensing Environmental**, v. 156, p. 276-293. 2015.

RIBEIRO, J. W; VANCINE, M. Classificador de imagens digitais Ls Autoclass. Rio Claro, SP, 2015.

RIBEIRO, M. C.; FIGUEIRA, J. E. C. Uma abordagem histórica do fogo no Parque Nacional da Serra do Cipó, Minas Gerais – Brasil. **Biodiversidade Brasileira**, ano 1, Nº 2, p. 212-227. 2011.

ROLLINS, M. G.; KEANE, R. E.; PARSONS, R. A. Mapping fuels and fire regimes using remote sensing, ecosystem simulation, and gradient modeling. **Ecological Applications**, v. 14, n. 1, p. 75-95. 2004.

ROY, D. P.; LEWIS, P.E.; JUSTICE, C. O. Burned area mapping using multi-temporal moderate spatial resolution data—a bi-directional reflectance model-based expectation approach. **Remote Sensing Environmental**, v. 83, p. 263-286. 2002.

R STUDIO TEAM. RStudio: Integrated Development for R. RStudio, Inc., Boston, MA. 2016. Disponível em <<http://www.rstudio.com/>>. Acesso em> 21 jul. 2016.

RUBAN, D. A. Quantification of geodiversity and its loss. **Proceedings of Geologist's Association**, v. 121, p. 326-333. 2010.

SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. **Cerrado: Ecologia e Flora**. 1 ed. Brasília: Embrapa, 2008. 408 p. (Volume 1).

Serviço Geológico Brasileiro CPRM. **Projeto SIG Geologia Ambiental do Brasil ao Milionésimo: Procedimento no tratamento de dados**. 2006. 54 p. Disponível em: <<http://geobank.cprm.gov.br/>>. Acesso em: 08 set. 2016.

Serviço Geológico Brasileiro CPRM. **Informações ao Usuário e Conteúdo do Sistema de Informação Geográfica (SIG)**. 2010. 19 p. Disponível em: <[http://www.cprm.gov.br/publico/media/InformacoesUsuario\\_MG.pdf](http://www.cprm.gov.br/publico/media/InformacoesUsuario_MG.pdf)>. Acesso em: 17 jul. 2016.

SHAFFER, M. Special section: Conserving nature's stage - Editorial. **Conservation Biology**, v. 29, n. 3, p. 611-612. 2015.

SCHULTZ, M.; CLEVERS, J. G. P. W.; CARTER, S.; VERBESSELT, J.; AVITABILE, V.; QUANG, H. V.; HEROLD, M. Performance of vegetation indices from Landsat time series in deforestation monitoring. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 318-327. 2016

UNESCO - United Nations Educational, Scientific and Cultural Organization. MAB (Man and Biosphere Programme) Biosphere Reserves Directory. **Espinhaço Range**. Disponível em: <<http://www.unesco.org/mabdb/br/brdir/directory/biores.asp?code=BRA+06&mode=all>>. Acesso em: 17 ago. 2016.

USGS - United States Geological Survey. **The Landsat 8 Data User's Handbook**. Versão 2.0. 2016. Disponível em: <<http://landsat.usgs.gov/documents/Landsat8DataUsersHandbook.pdf>>. Acesso em: <30 ago. 2016>.


WEGMANN, M.; LEUTNER, B.; DECH, S. **Remote Sensing and GIS for Ecologists: Using Open Source Software**. 1 ed. Exeter (UK): Pelagic Publishing, 2016. 352 p. Sem paginação. Disponível em: <<https://books.google.com.br/books?id=rCCUCwAAQBAJ&printsec=frontcover&hl=pt-BR#v=onepage&q&f=false>>. Acesso em: 23 ago. 2016.

ZHANG, L.; JIA, K.; LI, X.; YUAN, Q.; ZHAO, X. Multi-scale segmentation approach for object-based land cover classification using high-resolution imagery. **Remote Sensing Letters**, v. 5, n. 1, p. 73-82. 2013.


APÊNDICE



2330320



2330321



2330220



2330221



2330120



2330121



2330122



2330020



2330021

Figura 3 - Cenas do satélite RapidEye utilizadas no mapeamento. Composição colorida das imagens pelas bandas R1G2B3.