



JEFFERSON FRANCISCO SOARES

**ANÁLISE ORIENTADA A OBJETOS DE
IMAGENS DE SATÉLITE PARA
MAPEAMENTO DE ÁREAS DE
PRESERVAÇÃO EM RESERVATÓRIO
HIDRELÉTRICO.**

LAVRAS - MG

2015

JEFFERSON FRANCISCO SOARES

ANÁLISE ORIENTADA A OBJETOS DE IMAGENS DE SATÉLITE
PARA MAPEAMENTO DE ÁREAS DE PRESERVAÇÃO EM
RESERVATÓRIO HIDRELÉTRICO.

Dissertação apresentada à Universidade Federal de Lavras como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Engenharia Agrícola, para obtenção do título de mestre.

Orientador:

Dra. Gláucia Miranda Ramirez

Coorientadora:

Mirléia Aparecida de Carvalho

LAVRAS - MG

2015

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Soares, Jefferson Francisco.

Análise orientada a objetos de imagens de satélite para
mapeamento de áreas de preservação em reservatório hidrelétrico. /

Jefferson Francisco Soares. – Lavras: UFLA, 2015.

67 p.: il.

Dissertação (mestrado acadêmico) –Universidade Federal de
Lavras, 2015.

Orientador(a): Gláucia Miranda Ramirez.

Bibliografia.

1. Sensoriamento remoto. 2. Quickbird. 3. Matas ciliares. 4.
Algoritmo watersheds by immersion. 5. Exatidão global. I.

Universidade Federal de Lavras. II. Título.

JEFFERSON FRANCISCO SOARES

ANÁLISE ORIENTADA A OBJETOS DE IMAGENS DE SATÉLITE
PARA MAPEAMENTO DE ÁREAS DE PRESERVAÇÃO EM
RESERVATÓRIO HIDRELÉTRICO.

Dissertação apresentada à Universidade Federal de Lavras como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Engenharia Agrícola, para obtenção do título de mestre.

APROVADA em 26 de fevereiro de 2015.

Dra. Gláucia Miranda Ramirez	UFLA
Dra. Mirléia Aparecida Carvalho	UFLA
Dra. Margarete Marin Lordelo Volpato	EPAMIG

Orientador:

Dra. Gláucia Miranda Ramirez

LAVRAS - MG

2015

Dedico a minha querida Mãe, Marli Mesquita de
Souza Soares (in memoriam), que do céu me guarda,
protege, ilumina e guia meus passos.

AGRADECIMENTO

Agradeço a Deus, presente em todos os momentos de minha vida, e sem Ele, com certeza eu não estaria aqui;

À Universidade Federal de Lavras, pelas oportunidades oferecidas ao longo do Mestrado;

A Coordenação de Aperfeiçoamento de Pessoas de Nível Superior pelo apoio;

A minha orientadora, Gláucia Miranda Ramirez, o meu agradecimento especial pela, amizade, orientação, ajuda, incentivo e apoio dedicados neste ano, sem esta oportunidade nada disso seria possível. Obrigado por todas as oportunidades de aprendizado e crescimento, tanto acadêmico como pessoal;

Agradeço ao meu pai, Francisco Donizetti Soares, que sempre apoiou-me e inspirou-me, servindo de exemplo de caráter e personalidade;

A minha coorientadora, Mirléia Aparecida Carvalho, pelas experiências e conhecimento trocados, pela nossa amizade que se formou e pelos bons momentos vividos meio a muitas alegrias;

A minha mãe, Marli Mesquita de Souza Soares, que AMO de paixão, que tornou-me o homem que eu sou hoje, e sei que está no céu orando, guiando e intercedendo por todos os meus passos aqui na terra;

Aos meus irmãos, Suelba e Walisson, pela ajuda, confiança, carinho, apoio e confiança que me deram desde sempre;

Aos meus sobrinhos, Ana Júlia, Felipe e Vinícius, pelos momentos de descontração e alegria que sempre me proporcionam;

Aos “agregados”, Ronaldo, Perla, Francielly, Erickson e Vanda, pelos momentos felizes de descontração que passamos juntos;

Aos meus familiares que mesmo distantes sempre estão presentes em meu coração;

Agradeço ao Consórcio AHE FUNIL, pela oportunidade e confiança de trabalhar nesta empresa e desenvolver este trabalho, pela permissão do uso da imagem e por me ensinar o verdadeiro sentido do profissionalismo e da amizade;

Aos funcionários da Secretaria da Pós Graduação, em especial à Helem Cristina que sempre nos atendeu com a sua voz meiga e suave, resolvendo nossos problemas e a todos os professores e profissionais que me ajudaram a traçar essa minha nova trajetória;

Aos bons amigos de escola Mário, Deiwison, Thiago e Thiaguinho que sempre estiveram comigo mesmo nos momentos “Joselito” e suas respectivas cônjuges Renata, Milena, Suellem e Maressa, obrigado pela amizade incondicional;

Aos meus amigos do Laboratório de Geoprocessamento do Departamento de Engenharia, a grande amiga Christiany Mattioli, Otávio Nassur, Lays Horta, Thálita Carrijo e Hederson Kelison;

E por último e não menos importante à Mirelly Caroline Alves, pelos momentos felizes repletos de amor, carinho, amolação e companheirismo sempre.

Obrigado a todos!

RESUMO

Considerada uma das práticas vegetativas de mitigação da degradação dos recursos hídricos, a manutenção das matas ciliares é recomendada e exigida por lei. Contudo, no Brasil, ainda há uma progressiva e constante descaracterização destas áreas. Diante de tal realidade torna-se necessário ampliar pesquisas que permitam caracterizar as áreas de forma integrada, gerando resultados eficientes com rapidez e baixo custo. O sensoriamento remoto é uma opção que demonstra grande potencial de aplicação. Diante do exposto, o objetivo deste trabalho foi mapear e caracterizar o uso e ocupação do solo nas áreas de preservação permanente do reservatório da Usina Hidrelétrica de Funil (UHE Funil), utilizando imagem de satélite de alta resolução espacial - Quickbird- em composição verdadeira (RGB-321) aliada às técnicas de análise orientada a objetos. Para segmentação da imagem, a partir do algoritmo *watersheds by immersion*, utilizou-se o software Envi EX[®] 4.8. Para a classificação da imagem utilizaram-se os algoritmos *K-nearest neighbor*, *Support vector machine* e *Maximum Likelihood*. Analisou-se a acurácia dos mapeamentos comparando-se os resultados obtidos com o mapa gerado a partir da classificação visual da imagem da área de estudo (mapa de referência). A partir da análise dos resultados concluiu-se que o algoritmo *K-nearest neighbor* foi o melhor método para o mapeamento de uso e ocupação do solo da área de estudo, com índice *kappa* de 0,88 e exatidão global de 91,40%.

Palavras-chave: Sensoriamento remoto, Quickbird, matas ciliares, algoritmo *watersheds by immersion*, índice *kappa*, exatidão global.

ABSTRACT

Considered one of the vegetative mitigation practices for water resource degradation, the maintenance of riparian woods is recommended and demanded by law. However, in Brazil, these areas are still uncharacterized. In light of this reality, it becomes necessary to widen researches that allow us to characterize these areas in an integrated manner, generating efficient and quick results with low cost. Remote sensing is the option that demonstrates great application potential. Thus, in this work, we aimed at mapping and characterizing soil use and occupation in permanent preservation areas at the Funil Hydroelectric Power Plant (Funil HEP) reservoir, using high spatial resolution satellite imaging – Quickbird – in true composition (RGB-321) allied to object-oriented analysis techniques. For image segmentation, based on the watersheds by immersion algorithm, we used the Envi EX[®] 4.8 software. In order to classify the image, we used the algorithms *K-nearest neighbor*, *Support vector machine* and *Maximum Likelihood*. We analyzed the accuracy of the mappings comparing the results obtained to the map generated with the visual classification of the image of the study area (reference map). With the results, we concluded that the *K-nearest neighbor* algorithm was the best for mapping soil use and occupation in the study area, with kappa index of 0.88 and global accuracy of 91.40%.

Keywords: Remote sensing, Quickbird, riparian woods, watershed by immersion algorithm, kappa index, global accuracy.

LISTA DE FIGURAS

Figura 1: Reservatório da Usina Hidrelétrica do Funil e área de entorno.....	27
Figura 2: Fluxograma da metodologia utilizada.	29
Figura 3: Mapa de referência dos usos na área de entorno do reservatório da UHE Funil	35
Figura 4: Mapa de classificação visual da APP da UHE Funil.....	38
Figura 5: Mapa da classificação de imagem utilizando o algoritmo Maximum likelihood.....	39
Figura 6: Mapa da Análise orientada a objeto utilizando o algoritmo K-nearest neighbor.....	43
Figura 7: Mapa da Análise de imagem orientada a objeto utilizando o algoritmo Support Vector Machine.....	48

LISTA DE TABELAS

Tabela 1: Especificações técnicas do satélite QUICBIRD.....	10
Tabela 2: Escala de área mínima mapeável (STRECK et al. 2002).....	12
Tabela 3: Índice Kappa.....	23
Tabela 4: Bandas do satélite QUICKBIRD.....	28
Tabela 5: Quantificação da área de entorno classificada visualmente.....	36
Tabela 6: Quantificação da APP classificada visualmente.....	38
Tabela 7: Quantificação da APP utilizando o algoritmo <i>Maximum likelihood</i>	40
Tabela 8: Matriz de confusão utilizando o algoritmo <i>Maximum likelihood</i> ..	41
Tabela 9: Acurácia do usuário e acurácia do produtor.	42
Tabela 10: Quantificação da APP utilizando o algoritmo <i>K-nearest neighbor</i>	44
Tabela 11: Matriz de confusão utilizando o algoritmo K-nearest neighbor.	45
Tabela 12: Acurácia do usuário e acurácia do produtor.....	46
Tabela 13: Quantificação da APP utilizando o algoritmo Support vector machine.....	48
Tabela 14: Matriz de confusão da classificação utilizando o algoritmo Support Vector Machine.....	50
Tabela 15: Acurácia do usuário e acurácia do produtor.....	50
Tabela 16: Valores de índice kappa e exatidão global para cada método de classificação analisado.	52

Tabela 17: Comparação da acurácia do Usuário e do Produtor para cada classe entre os algoritmos Support vector machine k-nearest neighbor e Maximum likelihood.....54

LISTA DE GRÁFICOS

Gráfico 1: Quantificação do mapa de referência e da classificação utilizando algoritmo K-nearest neighbor.	42
Gráfico 2: Quantificação do mapa de referência e da classificação utilizando algoritmo K-nearest neighbor	47
Gráfico 3: Quantificação do mapa de referência e da classificação utilizando algoritmo Support vector machine.....	51
Gráfico 4: Quantificação das classes da área de estudo por meio do mapa de referência e dos algoritmos de classificação K-nearest neighbor, Maximum likelihood e Support Vector Machine.	53
Gráfico 5: Comparação da acurácia do Usuário e do Produtor para cada classe entre os algoritmos Support vector machine k-nearest neighbor e Maximum likelihood.....	55

LISTA DE SIGLAS

UHE	Usina Hidrelétrica
APP	Área de Preservação Permanente
SIG	Sistema de Informação Geográfica
REM	Radiação Eletromagnética
NOAA	<i>National Oceanic and Atmospheric Administration</i>
CCD	<i>Charge Coupled Device</i>
AMM	Área Mínima Mapeada
GNSS	<i>Global Navigation Satellite System</i>
RTK	<i>Real Time Kinematic</i>
GPS	<i>Global positioning system</i>
INCRA	Instituto Nacional de Colonização e Reforma Agrária

SUMÁRIO

1.	INTRODUÇÃO.....	1
2.	OBJETIVO.....	3
2.1	Objetivo geral.....	3
2.2	Objetivos específicos.....	3
3.	REVISÃO DE LITERATURA	4
3.1	Áreas de preservação permanente	4
3.2	Geotecnologias	5
3.2.1	Sensoriamento remoto.....	6
3.2.2	Sistema de informação geográfica.....	6
3.2.3	Diferentes sensores utilizados no estudo de APP.....	7
3.2.4	O satélite QUICKBIRD.....	9
3.2.5	Processamento de imagem	11
3.3	Classificadores de imagem.....	13
3.3.1	Classificação visual	14
3.3.2	Classificação não-supervisionada.....	15
3.3.3	Classificação supervisionada.....	17
3.3.4	Segmentação de imagens e análise orientada a objetos.....	19
3.4	Testes estatísticos	23
4.	MATERIAL E MÉTODOS.....	26
4.1	Área de estudo.....	26
4.2	Material	28
4.2.1	Imagem QUICKBIRD.....	28
4.2.2	<i>Softwares</i>	28
4.3	Etapas	29
4.3.1	Levantamento de dados	30
4.3.1.1	Levantamento Planialtimétrico.....	30
4.3.1.2	Referência de Campo	31

4.3.1.3	Classificação <i>Maximum Likelihood</i>	31
4.3.1.4	Análise orientada a objeto	31
4.3.1.5	Segmentação.....	31
4.3.1.6	Classificação utilizando <i>K-nearest neighbor</i> e <i>Support vector machine</i>	33
4.3.1.7	Estatística	34
5.	RESULTADOSE DISCUSSÃO	35
5.1	Mapa referência.....	35
5.2	Área mínima mapeada.....	36
5.3	Classificação de imagens.....	36
5.3.1	Classificação visual da APP da UHE Funil.....	36
5.3.2	Classificação de imagem utilizando o algoritmo <i>Maximum likelihood</i>	39
5.3.3	Classificação da imagem utilizando o algoritmo <i>K-nearest neighbor</i>	43
5.3.4	Análise orientada á objeto utilizando o algoritmo <i>Support vector machine</i>	47
5.4	Comparação entre os classificadores.....	52
5.4.1	Índice Kappa e Índice de Exatidão Global	52
5.4.2	Acurácias do Usuário e do Produtor.....	54
6.	CONCLUSÃO.....	56
7.	REFERÊNCIA BIBLIOGRAFICA.....	57

1. INTRODUÇÃO

O conceito de áreas de preservação permanente (APP) advém do reconhecimento da sociedade sobre a importância em conservar a vegetação em localidades próximas as bacias hidrográficas e seus constituintes. Devido a sua importância, atualmente faz-se necessário monitorar estas áreas de maneira eficiente. Entre tantas iniciativas de organizações sociais e governamentais, certas ações são consideradas promissoras, dentre elas pode-se citar as leis que regem o uso dos recursos naturais.

Considerada uma das práticas vegetativas de mitigação da degradação dos recursos hídricos, a manutenção das matas ciliares é recomendada e exigida por lei. No Brasil, o Código Florestal Brasileiro regulamentado pela Lei 12.651, de 25 de maio de 2012 estabelece as áreas fixas de vegetação a ser protegidas ao redor de lagos artificial, com a função de preservação permanente.

Apesar das leis que regulamentam a manutenção e recuperação das áreas de preservação permanentes (APP), ainda há a progressiva e constante descaracterização destas áreas. Diversas são as causas desta situação, a exemplo da inexistência da demarcação oficial, a deficiência do estado em promover uma fiscalização ambiental, a indisponibilidade de conhecimento e métodos operacionais que viabilizem estas fiscalizações.

Neste contexto, os sistemas de informações geográficas (SIG) podem servir de ferramenta auxiliar no controle e fiscalização das APP, a partir da junção dos dados de sensores remotos às técnicas de processamento digital de imagens.

Estudos comprovam que apesar da possibilidade de se realizar a delimitação e mapeamento da cobertura da terra, de áreas protegidas por lei, a partir de dados de sensores remotos são necessários estudos que permitam o conhecimento dos fatores que podem determinar a não preservação da cobertura vegetal nestas áreas. Portanto, com a utilização de técnicas de sensoriamento remoto integradas aos SIG existe a possibilidade de se produzir

diagnósticos, considerando os principais agentes e especificidades regionais, de modo a melhorar a compreensão dos processos que induzem ou não à proteção das APP.

A utilização de imagens de alta resolução espacial é uma alternativa ao uso das fotografias aéreas e de imagens de média resolução no delineamento e monitoramento das APP. Dentre as vantagens pode-se destacar a possibilidade de aquisições periódicas e a cobertura de grandes áreas a custos relativamente baixos, quando comparadas com os das fotografias aéreas e permitem uma caracterização mais precisa das diferentes fitofisionomias que as APP podem englobar, quando comparadas com as imagens de media resolução espacial.

Nos dias atuais, com a grande disponibilidade de imagens de alta resolução espacial no mercado abriram-se novas perspectivas para o estudo e mapeamento da vegetação natural. A maioria dos satélites que geram imagens de alta resolução espacial é limitada a quatro bandas espectrais o que dificulta o estudo de algumas formações vegetais. No Brasil esse problema é agravado, pois as empresas privadas e alguns órgãos governamentais que compram essas imagens têm preferência pelo produto pré-processado e com composição em cores naturais, dificultando a identificação e o monitoramento das formações vegetais naturais.

De modo a suprir as limitações espectrais das imagens de alta resolução espacial é possível utilizar técnicas de tratamento digital de imagens mais robustas e modernas como é o caso da análise orientada a objeto. Com isso, a partir da utilização de imagens de alta resolução espacial, com composição em cores verdadeiras, aliada às técnicas de análise orientada a objeto é possível mapear e identificar os conflitos de uso do solo nas APP.

2. OBJETIVO

2.1 Objetivo geral

Com este trabalho objetivou-se realizar o mapeamento e caracterização do uso do solo nas APP do reservatório da Usina Hidrelétrica de Funil (UHE Funil) utilizando imagens de satélite de alta resolução espacial em composição verdadeira (RGB-321) aliada às técnicas de análise orientada a objetos.

2.2 Objetivos específicos

- Identificar os melhores limiares de segmentação na identificação e caracterização das APP;
- Avaliar a acurácia dos mapas obtidos a partir de técnicas de classificação orientada a objeto em imagens de alta resolução;
- Comparar a análise orientada a objetos com a classificação pixel a pixel;
- Discriminar e quantificar os diferentes tipos de uso do solo dentro das áreas de preservação.

3. REVISÃO DE LITERATURA

3.1 Áreas de preservação permanente

As APP têm importância vital para o equilíbrio ambiental e ecológico do planeta, o que significa que não são áreas apropriadas para alteração de uso da terra, devendo estar cobertas com a vegetação original (DIETZOLD; WENDEL, 2004).

A presença de cobertura vegetal nestas áreas atenua diversos efeitos nocivos ao ambiente, além de minimizar os processos erosivos e a lixiviação dos solos promove a regularização do fluxo hídrico, o aumento da infiltração de água no solo e a redução do assoreamento dos cursos d'água e reservatórios gerando benefícios para a fauna e flora.

Matas ciliares são áreas de transição entre os ecossistemas terrestre e o aquático influenciadas por ambos. Têm a função de regular as transferências de energia e nutrientes de um ecossistema para outro (CAVALCANTI; LOCKABY, 2006; COLLINS et al., 2010; CORRELL, 2001; KAGEYAMA et al., 2002; LIMA, 1998). Quando localizadas em áreas agrícolas, previnem ou minimizam a movimentação de sedimentos gerados pelos os processos erosivos (ADDISCOTT, 1997).

Vale ressaltar que a maioria dos contaminantes químicos presentes em águas subterrâneas e superficiais, está relacionada às fontes agrícolas. Os agrotóxicos, compostos orgânicos voláteis e metais apresentam grandes riscos para o equilíbrio da fauna e flora aquática. Apresentam, sobretudo riscos à saúde humana no uso público da água, sendo amplamente conhecida a estreita relação entre a qualidade da água e as inúmeras enfermidades que acometem as populações e a presença de cobertura vegetal nestas áreas atenua diversos destes efeitos (HU; KIM, 1994; LIBÂNIO; CHERNICHARO; NASCIMENTO, 2005).

A legislação ambiental brasileira contempla inúmeras leis visando à preservação da saúde do meio ambiente, dentre elas, o Código Florestal,

Constituição Federal, Lei de Crimes Ambientais, Política Nacional de Meio Ambiente. O Código Florestal brasileiro foi editado em sua primeira versão em 1934 e já contemplava alguns conceitos de preservação de áreas marginais a cursos d'água, contudo não delimitava distâncias mínimas a serem preservadas. Em 1965, a Lei 4771, definiu as distâncias a serem preservadas das margens dos córregos e rios, deixando sem definições os critérios de distâncias e os parâmetros de proteção para tanques e represamentos artificiais, nascentes e topo de morro (BRASIL, 1965). Em 2012 a lei 12.651 foi aprovada pelo governo, o novo Código Florestal estabelece limites para o uso e ocupação do solo de quaisquer APP.

De acordo com a lei 12.651, de 25 de maio de 2012, Art. 62, os reservatórios artificiais de água destinados à geração de energia ou abastecimento público que foram registrados ou tiveram seus contratos de concessão ou autorização assinados anteriormente à Medida Provisória nº 2.166-67, de 24 de agosto de 2001, a faixa de APP deverá ser a distância entre o nível máximo operativo normal e a cota máxima maximorum desse reservatório (BRASIL, 2012).

A lei estadual que dispõem sobre a Política Florestal de Proteção à Biodiversidade no Estado de Minas Gerais descrita na Lei Estadual Nº 20.922, Art. 22, parágrafo único, que poderia ser mais restritiva que a lei federal, quanto à delimitação das APP manteve a igualdade com a mesma (MINAS GERAIS, 2013).

3.2 Geotecnologias

Os avanços das geotecnologias contribuem para a aquisição e manipulação das informações sobre a superfície terrestre, em especial sobre os recursos naturais.

3.2.1 Sensoriamento remoto

Segundo Souza (2010) as ocupações irregulares em áreas de preservação vêm ocorrendo com frequência, em muitos casos pela proliferação de loteamentos irregulares e pela inexistência de infraestrutura nessas áreas, transformando a urbanização um fator de risco real sobre os recursos naturais. A carência de fiscalização favorece o crescimento e ocupações desordenadas prejudicando o meio ambiente.

A demanda de produtos de alta resolução espacial para subsidiar o planejamento e a modelagem ambiental tem crescido mundialmente. Diversas são as áreas de estudo que os utiliza para a classificação e identificação de áreas com vegetação natural, um dos principais fatores é a exatidão dos dados dessas imagens, o que torna mais precisa a quantificação destes levantamentos.

Em geral, os sensores orbitais são sistemas ópticos-eletrônicos capazes de detectar e registrar, sob a forma de imagens, o fluxo de energia radiante que é refletido ou emitido por objetos da superfície terrestre. Em síntese, pode-se dizer que o sensoriamento remoto é um conjunto de técnicas que permite definir um determinado alvo à distância. O procedimento é feito por meio da análise da radiação eletromagnética (REM) refletida ou emitida por este alvo em determinadas faixas espectrais do espectro eletromagnético.

Os alvos, naturais ou artificiais, refletem ou emitem a REM de modo peculiar o que permite, desta forma, sua identificação. Este fato peculiar de refletir ou emitir a REM é denominado de assinatura espectral ou comportamento espectral (STEFFEN, 1996).

3.2.2 Sistema de informação geográfica

Segundo Câmara et al. (1996) técnicas de geoprocessamento fornecem ferramentas computacionais para o tratamento da informação geográfica. O sistema de informação geográfica (SIG) armazena a geometria

e os atributos dos dados que estão georreferenciados, isto é, localizados na superfície terrestre e numa projeção cartográfica.

Segundo Rocha (2000), SIG é um sistema com capacidade para aquisição, armazenamento, tratamento, integração, processamento, recuperação, transformação, manipulação, modelagem, atualização, análise e exibição de informações digitais georreferenciadas, topologicamente estruturadas, associadas ou não a um banco de dados alfanuméricos.

Os SIG admitem a manipulação dos dados de diversas fontes como mapas, imagens e cadastros. Além disso, permite uma ampla utilização dos dados no planejamento urbano e regional, no estudo de recursos naturais, na análise multitemporal e na avaliação e caracterização de bacias hidrográficas. Portanto, o SIG pode constituir uma importante ferramenta para a análise, monitoramento e fiscalização dos ambientes naturais (CÂMARA et al., 1996).

Os SIG permitem a análise espacial por meio da utilização de vários elementos do meio ambiente de forma integrada, gerando resultados eficientes com rapidez e baixo custo (PORTES et al., 2009). Almeida, Santos e Pezzopane (2007) utilizando avançadas técnicas computacionais obtiveram excelentes resultados na identificação e delimitação das APP no município de Alegre, ES, delimitando as APP com a utilização de cartas topográficas em escala de 1:10.000 e 1:50.000

3.2.3 Diferentes sensores utilizados no estudo de APP

Técnicas de sensoriamento remoto e de SIG têm sido utilizadas para mapear APP, detectar e avaliar o percentual das áreas que se encontram em desacordo ao Código Florestal.

Rovani e Cassol (2012) utilizaram dados do TM/LANDSAT-5 em composição RGB-345 e dados cartográficos para avaliar as mudanças ocorridas nas APP e seus possíveis conflitos ambientais entre os anos de 2000 e 2010 no município de Barão de Cotegipe, RS. Os resultados permitiram identificar cinco tipos diferentes de uso do solo, sendo eles água, área urbana,

culturas, floresta e solo exposto encontrados nas APP. Estes usos representaram 12,77% da área total, ou seja, essa APP está sendo degradada pelo uso indevido do solo.

Em estudos realizados por Valle Junior et al. (2010), a partir da utilização de imagens do satélite CBERS 2 com composição de bandas RGB-341, foi possível classificar automaticamente APP e identificar os conflitos de uso na bacia hidrográfica do rio Tijuco, demonstrando o déficit destas áreas as margens do rio.

Soares et al. (2011) obtiveram em seus estudos ótimos resultados na delimitação de APP e identificação dos conflitos legais do uso da terra na bacia Hidrográfica do Ribeirão São Bartolomeu – MG. Utilizando imagens do satélite IKONOS II, com resolução espacial de 1m, foi possível realizar o mapeamento de nove classes de cobertura e uso da terra, com base na interpretação visual. Como resultado, do total das áreas de preservação identificadas, somente 40,30% está protegida e encontra-se cobertas com vegetação natural, demonstrando que o Código Florestal Brasileiro não está sendo cumprido.

Costa et al. (2013) utilizando imagens de alta resolução do sensor IKONOS II com composição colorida RGB-123, mapeou e avaliou os conflitos de uso do solo nas APP da bacia hidrográfica do ribeirão São Bartolomeu, localizada no município de Viçosa, MG. Os autores identificaram nove classes conflitantes de uso dentro das APP, utilizando a classificação visual, assim puderam comparar os dados quantitativos de um levantamento realizados no ano de 1987 com levantamento utilizando sensores de alta resolução espacial. O estudo concluiu que a utilização de imagens de sensores de alta resolução garante uma excelente classificação, qualidade e confiabilidade dos dados produzidos, considerando como ponto negativo o tempo para análise.

3.2.4 O satélite QUICKBIRD

No final da década de 90, com o pensamento de suprir as lacunas da série dos satélites LANDSAT e de outros satélites de media resolução, o governo dos Estados Unidos da América liberou o uso cívil de imagens de alta resolução espacial. As primeiras imagens liberadas para esse fim foram as do satélite IKONOS II.

No ano de 2000 a empresa Norte Americana DIGITALGLOBE que é responsável pelo programa QUICKBIRD obteve a licença da *National Oceanic and Atmospheric Administration* (NOAA) para criação de um sistema com alta resolução espacial.

Com o insucesso do lançamento do QUICKBIRD-1, seu sucessor, QUICKBIRD-2 foi colocado em órbita em outubro de 2001 da base norte americana *Vandenberg Air Force Base*. O satélite continua em operação até o presente momento, oferecendo imagens comerciais de alta resolução espacial com dados de 0,61 m de resolução espacial no modo pancromático e 2,4 m no modo multiespectral (JACOBSEN, 2003).

A empresa *Ball Aerospace & Technologies* foi responsável pela construção do telescópio do sensor do satélite com suas óticas de espelho, bem como pelo veículo transportador. O plano focal incluindo o *Charge Coupled Device* (CCD) linear, instalações de compressão de imagem e eletrônica associada foram fornecidas pela Kodak (PETRIE, 2002). O Satélite possui órbita heliossíncrona, com inclinação de 97,2°.

O satélite possui sensores do tipo CCD, que realizam varredura eletrônica em fileira linear (*pushbroom linear array*) flexíveis para visadas *off-nadir* de até 30°, ao longo do terreno (*along-track*) imageado (PETRIE, 2002).

Em 1986 o satélite SPOT foi uma das primeiras plataformas espaciais a utilizar sensores do tipo CCD *pushbroom*. Outros satélites como IKONOS-II, o CBERS também utilizaram este sistema de imageamento. No sensor de varredura eletrônica, todos os detectores da barra do CCD são amostrados

simultaneamente para uma mesma linha (SCHOWENGERDT, 2006). O sistema sensor do QUICKBIRD captura imagens no modo pancromático e multiespectral e são comercializadas em três diferentes níveis de correção, Básica (*Basic*), Padrão (*Standard*) e Ortoretificada (*Orthorectified*). As especificações técnicas do satélite QUICKBIRD são descritas na Tabela 1.

Tabela 1: Especificações técnicas do satélite QUICKBIRD.

Altitude da órbita	450km
Inclinação da órbita – Linha do Equador	97.2°
Sentido da órbita	Descendente 10:30 a.m.
Duração da órbita	93.6min.
Tipo de órbita	Heliossíncrona
Tempo de Revisita	5,9 dias a 20° off-nadir ou menos
Largura nominal da faixa imageada	16.5km (nadir) 20,8km (off-nadir)
Resolução e largura das bandasespectrais do sensor	2,44 m - Blue: 430 – 545 nm 2,44 m - Green: 466 – 620 nm 2,44 m - Red: 590 – 710 nm
Resolução e largura das bandasespectrais do sensor	2,44 m - Near-IR: 715 – 918 nm 0,61 m Pancromática 405 - 1053
Resolução Radiométrica	11 bits (2048 níveis de cinza)
Precisão Métrica	23m CE, 17m erro linear (sem ponto de controle).
Massa do satélite	1018 kg
Capacidade do satélite	200.000 km ² por dia

Fonte: Adaptada de DigitalGlobe (2014)

3.2.5 Processamento de imagem

A imagem ortorretificada (Orthorectified Imagery) é ideal para mapeamentos e SIG, para a verificação de mudanças de uso da terra e aplicações que necessitam de alto grau de exatidão. Conforme DigitalGlobe (2014) nestas imagens duas fontes de distorções são corrigidas: distorção introduzida devido à geometria de visada, inclusive efeitos topográficos e distorção introduzida devido ao sensor.

Segundo a DigitalGlobe (2014) na correção das bandas multiespectrais as distorções derivadas da geometria de visada utilizam informações de uma única faixa imageada, posteriormente aplicada a todas as faixas imageadas de cada banda. As correções das distorções do sensor incluem informações específicas das bandas. Estas correções incluem uma compensação para assegurar o registro entre as bandas. No processo de correção são realizados cálculos para o ajuste da geometria de visada, e estes são combinados com as correções da geometria do sensor e aplicados individualmente às faixas, resultando em uma imagem retificada e registrada.

Celestino, Saldanha e Rocha (2007) após analisarem imagens do satélite QUICKBIRD concluíram que a escala máxima que pode ser utilizada na geração de bases cartográficas, por meio dessas imagens é de 1:1800 para o modo pancromático ou fusionado, com um PEC de 0,9 m, carta padrão classe. Portanto, para escalas maiores, como 1:1000, essas imagens não devem ser utilizadas.

Martinelli (1994) informa que a escala e a Área Mínima Mapeável devem obedecer a uma dimensão que atenda aos objetivos do que se deseja estudar e mapear. Por fim, é conveniente destacar que dependendo da escala utilizada o tamanho da Área Mapeável define o tamanho do erro aceitável num mapeamento.

O conceito de Área Mínima Mapeável (AMM), associado à cartografia e define o tamanho da área que um determinado objeto deve conter para que seja representado num mapa ou carta geográfica. A noção de área

entende-se como o conjunto de *pixels* contínuos em uma imagem. Dent e Young (1981) e Streck et al. (2002) definem como sendo 0,4 m² o tamanho mínimo de uma área a ser apresentada num mapa temático de solos, considerando uma escala de 1:10.000, os valores de área referente as escalas estão descritas na Tabela 2.

Tabela 2: Escala de área mínima mapeável.

Escala	Área (ha)
1:1.000.000	4.000
1:750.000	2.250
1:500.000	1.000
1:100.000	40
1:50.000	10
1:20.000	1,6
1:10.000	0,4

$$AMM = (E^2 \times 0,4) / 10^8$$

Fonte: Streck et al. (2002)

Para o cálculo de MMA utilizou-se o conceito proposto pela EMBRAPA (EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA 2012), definido pela equação (1):

$$AMM = E^2 \times AP / K \quad (1)$$

Em que:

E é a escala fixa de mapeamento;

AP é a área do *pixel* da imagem;

K é a constante de mapeamento 10⁸.

Amaral et al. (2009) utilizando imagens de satélite de alta resolução espacial dos satélites CBERS e QUICKBIRD, para mapeamento de estádios

de sucessão florestal, nos municípios de Bugre e Ipaba, MG, realizaram classificações visuais, por *pixel* e por regiões e a fins de avaliar a fidedignidade da classificação de cada método, para tanto foi gerada a matriz de erros e calculado o índice *Kappa*. Neste estudo concluiu-se que a utilização de imagens dos satélites CBERS e QUICKBIRD foi eficiente apenas para separação do estágio inicial de sucessão secundária dos estágios avançado e médio.

Bernardi et al. (2007), compararam métodos de classificação em imagem de alta resolução do satélite QUICKBIRD na classificação de uso do solo na bacia do rio Santa Cruz, localizado no município de Lavras - MG, segundo os autores as imagens de alta resolução espacial do QUICKBIRD, necessitam de novas metodologias de tratamento. Os classificadores convencionais por *pixel* são menos adequados, sendo sugerido o uso do método de classificação orientada a objeto.

3.3 Classificadores de imagem

Existe um grande número de métodos de análise multicriterial para auxílio à tomada de decisão. Diferentes métodos geralmente representam distintas formas de aproximação para a tomada de decisão. A seleção do método depende do problema considerado, das preferências do analista entre outros fatores.

Com relação aos tipos de classificações digitais mais utilizadas, Moreira (2010), Guimarães e Diniz (2003) destacam as supervisionadas e não supervisionadas. Na primeira, os algoritmos utilizados realizam o processo de reconhecimento dos padrões, orientados por amostras de treinamento, que são fornecidas ao sistema de classificação pelo especialista. E o segundo tipo pode-se dizer que a identificação dos grupos naturais é definida sem a interferência de um especialista.

Em sensoriamento remoto, o mapeamento é realizado por meio da classificação de imagens orbitais, que podem ser feitas por meio de análise

visual (manual) ou automática, utilizando classificadores *pixel a pixel* ou baseado em objetos. Em ambas as classificações, o resultado associa a cada *pixel* da imagem um rótulo ou tema. Desta forma, uma imagem numérica é transformada numa imagem temática, onde o número de categorias é definido pelo próprio analista.

Segundo Moreira et al. (2010), os primeiros sistemas desenvolvidos para esta finalidade estavam voltados, única e exclusivamente, para a extração de informações das imagens orbitais. Ou seja, não utilizavam nenhum outro tipo de informação complementar, a não ser a experiência e observação do foto-intérprete.

3.3.1 Classificação visual

O processo de interpretação pode envolver vários níveis de complexidade, desde um simples reconhecimento direto de objetos na cena, até a influência das condições do lugar. Por outro lado pode, frequentemente, ser necessário inferir nas características das feições baseadas em suas aparências nas imagens.

Sistemas de interpretação de imagens baseados em conhecimento modelam em um ambiente computacional o conhecimento do foto-intérprete, emulando a sua capacidade de combinar dados de diferentes fontes e formatos na análise de imagens de sensores remotos (FEITOSA et al., 2005).

A classificação ou interpretação visual, mais conhecida como interpretação na tela do computador, permite identificar visualmente e digitalizar as classes. Por meio deste procedimento é possível aumentar a exatidão do mapa temático final, e são utilizadas geralmente em composição natural. A classificação via interpretação visual se limita ao uso de três bandas espectrais, já as classificações automáticas podem ser utilizadas quantas bandas o usuário desejar (CARVALHO, 2004). Na interpretação visual são identificados os elementos de interpretação de imagens, tais como: padrões de cor, textura, estrutura, forma, além de informações auxiliares de cunho

espacial. Esses padrões definem as características das classes de cobertura, que são digitalizadas diretamente sobre a imagem (AVERY; BERLIN, 1985). Este tipo de classificação é geralmente utilizado quando o objetivo é classificar uma área menor com maior precisão.

Novo, Hanson e Curran (1989) comentam que a interpretação visual de imagens baseia-se em certos princípios de análise (teste de hipótese, convergência de evidências etc.), técnicas de detecção e identificação (modelos de percepção, material colateral, visão estereoscópica) e elementos (tonalidade, cor, tamanho, forma etc.).

Borgonovi e Chiarini (1967) efetuaram o levantamento por fotointerpretação da cobertura vegetal de floresta natural e reflorestamento do Estado de São Paulo, com base em levantamento aéreo efetuado em 1962. Neste trabalho, as diferentes categorias de vegetação (mata, capoeira, cerradão, cerrado, campo cerrado e campo) foram agrupadas como floresta natural, com uma área de 3.405.800 ha, que representava 13,7% da área total do Estado.

Para Lillesand, Kiefer e Chipman (2004), os intérpretes mais eficientes, de modo geral, têm conseguido duplicar os poderes de interpretação pelo uso da imaginação e de uma grande parcela de paciência. Também sendo necessário um entendimento minucioso do fenômeno estudado e o conhecimento da região geográfica em estudo.

A interpretação visual de imagens de satélite, embora de grande utilidade para o mapeamento do uso e ocupação da terra, pode tornar-se inviável, quando aplicada a áreas muito extensas, pela grande demanda de tempo (VASCONCELOS; NOVO, 2001).

3.3.2 Classificação não-supervisionada

O método é dito não-supervisionado quando o classificador não utiliza, a priori, nenhum conhecimento sobre as classes existentes na imagem

e define, sem a interferência do analista, a estratificação da cena, atribuindo a cada *pixel* uma determinada classe.

Neste tipo de classificação, o algoritmo baseia-se na análise de agrupamentos onde são identificados no espaço de atributos os *clusters* formados por *pixels* com características espectrais similares. Define-se então, por meio de um limiar estabelecido pelo analista, quais as concentrações de *pixels* que devem ser tratadas como grupos distintos (RICHARDS, 1988).

Com a finalidade de identificar áreas prioritárias para recuperação florestal da bacia do Rio Corumbataí, SP, Valente (2005) utilizou imagens obtidas pelo sensor ETM+, a bordo do satélite LANDSAT-7 com composição colorida RGB-453 para a classificação do uso do solo, conseguiu assim priorizar a união dos fragmentos florestais nativos, independente do seu tamanho, de modo a restabelecer a conectividade entre os mesmos. Utilizando o classificador não-supervisionado foi possível identificar os fragmentos que se localizavam mais próximos, sendo possível dar uma maior prioridade nos fragmentos para recuperação visando à interligação dos mesmos.

Lopes (2008) em seus estudos caracterizou espacialmente o uso e ocupação do solo no município de Tailândia - Pará, por meio do satélite LANDSAT 5/TM, para quantificar a degradação do meio ambiente no município, utilizando a técnica de classificação não-supervisionada ISODATA, levando em consideração o objetivo com o seu trabalho, que foi caracterizar espacialmente a área e não diagnosticar a intensidade do impacto, a metodologia de classificação não-supervisionada foi satisfatória

Em uma descrição sucinta deste algoritmo de classificação, tem-se como primeira tarefa a definição do limiar de aceitação, referente à distância entre os centros iniciais dos clusters. Com isto, gera-se uma relação de regiões ordenada de forma decrescente por área. De um modo geral, as regiões de maior área são aquelas de maior representatividade da classe.

3.3.3 Classificação supervisionada

Segundo Blaschke et al. (2000), dentre os diferentes algoritmos atualmente utilizados em sensoriamento remoto, aqueles que permitem a inserção do contexto são os mais promissores em termos de confiabilidade.

A classificação de imagens de satélites tem como objetivo distinguir e identificar as características dos diferentes alvos em uma imagem, a exemplo das classes de vegetação, uso do solo, tipos de rochas, entre outros. Contudo, a técnica de classificação de imagens apresenta limitações no que se refere à simplificação das informações contidas em uma imagem, pois na verdade existe grande complexidade em uma cena de satélite (CRÓSTA, 1999).

Conforme Lillesand e Kiefer (1987), dentre os métodos iterativos de classificação ou classificadores supervisionados, os mais comuns são a classificação por paralelepípedo (*Single Cell*) e a classificação por Máxima Verossimilhança (*Maximum Likelihood*).

O método da classificação por *Maximum likelihood* baseia-se no cálculo da distância estatística entre cada *pixel* e a média dos níveis de cinza da classe previamente definida a partir de amostras de treinamento (DUTRA et al., 1981).

Neste tipo de classificação supervisionada, a probabilidade de um dado *pixel* pertencer a uma das classes predefinidas é calculada por uma função de probabilidade $P(x)$. O cálculo é realizado para o conjunto de classes que intervêm na classificação temática, ou seja, *pixel* é atribuído àquela classe que maximiza a função de probabilidade.

Volpe e Lombardo (2011) testaram diferentes tipos de classificadores (classificação visual, classificação automática não-supervisionada e automática supervisionada) em imagens de satélite de alta resolução do IKONOS II. Os autores determinaram o uso do solo no entorno do trecho do Rodoanel Mario Covas, na cidade de São Paulo, SP. e concluíram que ambas as classificações, visual e automática, obtiveram bons resultados e atenderam aos objetivos de quantificação. Contudo, levando em consideração a

abrangência da área de estudo, a classificação automática supervisionada foi apontada como a mais adequada das opções testadas na imagem de alta resolução IKONOS.

Santos et al. (2009) avaliando a influência da declividade na exatidão de mapeamentos de áreas cafeeiras no sul de Minas Gerais, utilizaram o classificador *Maximum likelihood* em imagem LANDSAT 5 com resolução de 10 metros. O classificador utilizado alcançou índice global de 72%, no entanto, a classe café, foco do estudo, teve um índice de 66%, confirmando a dificuldade de classificação de áreas cafeeiras utilizando o classificador *Maximum likelihood*.

Nestes métodos tradicionais de classificação supervisionado de imagens agrupam os *pixels* em classes tendo como base a característica espectral *pixel-a-pixel*. Os algoritmos desses métodos de classificação analisam a característica espectral de cada *pixel* da imagem e os categoriza dentro de uma classe específica por meio de métodos estatísticos. Essa abordagem pode não ser satisfatória para classificação de imagens de alta resolução em termos de precisão e produção de redundância, visto sua grande variabilidade de respostas espectrais.

Tratando-se de imagens de alta resolução espacial, a alta variância intra-classe não favorece a aplicação do método de classificação *pixel-a-pixel*, segundo Alencar-Silva e Maillard (2009), pode-se destacar entre outros problemas, o efeito *salt and pepper*, caracterizado por pequenos polígonos disseminados por toda a área mapeada e que acabam por demandar operações de pós-processamento, como filtros, para a sua eliminação.

De acordo com Franklin, Woodcock e Warbington (2003) algoritmos de classificação de imagens tradicionais baseadas em *pixels* não fazem uso de informação semântica na imagem e, assim, não são adequados para lidar com a heterogeneidade inerente típicos de unidades de cobertura da terra. Os mapas temáticos resultantes normalmente sofrem de um efeito de *salt and pepper* e geram informações de cobertura da terra inexatas, gerando mapas detalhados, mas com precisão limitada.

3.3.4 Segmentação de imagens e análise orientada a objetos

A utilização de algoritmos de segmentação de imagens tem sido amplamente empregada na extração de informações de imagens, principalmente em imagens de alta resolução. Estes algoritmos têm por objetivo dividir uma imagem em regiões espacialmente contínuas, separadas e homogêneas. Os processos de segmentação e classificação orientados a objetos possuem vantagens quando comparado ao processo de classificação por *pixels*, pois obtêm resultados visualmente consistentes.

Ao utilizar um método de segmentação do espaço urbano em imagens de alta resolução espacial por meio de integração espectral e de informações contextuais, é possível classificar um objeto individual como tal e não como uma mistura desordenada de *pixels* (THOMAS; HENDRIX; CONGALTON, 2003).

No algoritmo de segmentação são definidos dois limiares, o primeiro é o de similaridade, no qual duas regiões são consideradas similares e o segundo é o de área, valor de área mínima para que uma região seja individualizada. O limiar de similaridade é definido com base na distância euclidiana dada pela diferença entre os vetores de médias de duas regiões vizinhas (ESPINDOLA, 2005).

O fator fundamental da segmentação é a divisão de regiões que satisfaça as condições mencionadas acima. Cada região é homogênea com relação a alguma propriedade e é nessa fase que ocorre a extração de informações com base em características espectrais, espaciais e texturais (ROEDINK; MEIJSTER, 2001).

Segundo Carvalho (2011), o processo de segmentação é considerado o estágio inicial para a análise e classificação da imagem, pois a partir dela os objetos da imagem são gerados e seus atributos definidos. Assim, são necessários cuidados com a segmentação de imagem, uma vez que o resultado desta etapa do trabalho repercute positiva ou negativamente nas etapas seguintes da classificação (ARAÚJO, 2006).

Borges e Silva (2009) utilizou técnicas de segmentação de imagem para realizar o mapeamento da cobertura vegetal e o uso do solo em imagens de alta resolução do sensor ASTER, no município de Mucugê, BA. Neste estudo foi possível identificar seis tipos de classes diferentes de vegetação utilizando a composição colorida RGB-321. Os resultados alcançados demonstraram ser compatíveis com a realidade de campo e a validação da acurácia dos dados pelo índice *Kappa* foi de 0,76%, sendo considerada substancialmente correspondente. Foi ressaltada a necessidade da participação do especialista no processo de segmentação e classificação, que embora seja executada pelo computador, o operador é quem estabelece os critérios necessários e deve acompanhar e avaliar os resultados, devendo reiniciar o processo sempre que necessário.

Corte, Dlugosz e Centeno (2008) testaram os melhores limiares para segmentação de imagens SPOT-5 com resolução espacial de 5 metros, aplicadas ao reconhecimento de plantios florestais, em uma área de 3.376 hectares localizada no município de General Carneiro, PR. Os autores obtiveram resultados satisfatórios relativo à segmentação por crescimento de regiões, em imagem de alta resolução, na detecção de plantios florestais.

Alves et al. (1996) fizeram o mapeamento do uso da terra em Rondônia, Brasil, utilizando técnicas de segmentação baseado no crescimento por regiões e no uso de um classificador não supervisionado para classificação de imagens TM. Rotularam a paisagem em três unidades: floresta, área desmatada e vegetação secundária. Concluíram que os resultados gerais apresentados pela segmentação foram satisfatórios e que a técnica apresenta bom potencial para uso de atividades similares, podendo ser a base para a geração de mapas de uso da terra de forma eficiente.

Segundo Gonzales e Woods (2000), existem várias técnicas de segmentação: Por detecção de ponto, linha, borda e por limiarização, baseada em região, utilizando *watersheds* e, por último, pelo uso do movimento.

Uma das principais técnicas de segmentação é baseada na transformada de *watershed*, conhecida como divisor de águas (MEDEIROS,

2003). É considerada uma técnica de segmentação não hierárquica e por simulação de imersão (VINCENT; SOILLE, 1991).

O *software* ENVI EX, realiza segmentação das imagens utilizando o algoritmo *watershed by immersion*. Campos et al. (2013) compararam a eficácia de dois métodos de segmentação, por crescimento de regiões e por *watersheds by immersion*, disponibilizados pelos *softwares* SPRING - Sistema de Processamento de Imagens Georeferenciadas - e pelo ENVI EX, respectivamente. O estudo apontou que a segmentação por *watersheds* demonstrou melhores resultados em comparação com a segmentação por crescimento de regiões, descrevendo com maior eficácia a dinâmica ambiental da área de estudo.

Ao contrário dos métodos tradicionais para classificação digital de imagens, a análise orientada a objetos é realizada sobre objetos ou segmentos na imagem e não apenas sobre *pixels*. Na imagem um objeto representa uma entidade que pode ser individualizada, tem atributos próprios e as mesmas propriedades da classe que lhe deu origem (DEFINIENS, 2007).

Para Gonçalves, Fonseca e Caetano (2001), entre os motivos para se adotar a análise de imagem orientada a objetos pode ser considerado que o processamento de imagens aproxima-se mais dos processos cognitivos humanos que as análises baseadas em *pixel*, além de ser mais fácil incorporar informação de contexto numa abordagem orientada a objetos do que numa abordagem apenas por *pixel*.

A análise de imagens do tipo orientada a objeto opera da seguinte maneira: o programa executa algoritmos de segmentação para agrupar *pixels* semelhantes e adjacentes em polígonos ou em “objetos de imagem” ao invés das técnicas de processamento tradicionais que são baseadas somente nos valores dos *pixels* e, posteriormente realiza a classificação da imagem (NEWELL; OLOFSSON, 2008).

Campos et al. (2013) advertem sobre a ocorrência do aspecto granulado na classificação de imagens de alta resolução especial quando processado por classificadores automáticos convencionais. Os autores

sugerem a utilização do método baseado em objetos ou regiões para evitar este problema, uma vez que se utiliza da informação espectral e espacial de cada *pixel* e sua relação com seus vizinhos para reconhecer áreas homogêneas na classificação.

Leitold, Polizel e Moreira (2013) obtiveram resultados satisfatórios com a utilização da técnica de análise de imagem baseada em objeto, uma vez que foi possível agregar conhecimento do interprete ao processamento automático minimizando os erros de classificação, em estudos utilizando imagens de media resolução (TM/LANDSAT-5) para mapear o uso e cobertura da terra no município de Brasil Novo (PA).

Marujo et al. (2013) definiram um sistema de classificação automática de imagens de satélite RAPIDEYE, adequado para o mapeamento do uso da terra e ocupação da cultura do café no município de Três Pontas, MG. Foi proposta uma comparação entre dois métodos de classificação pós-segmentação, por regiões e orientada a objetos, onde obtiveram ótimos resultados estatísticos com ambos classificadores. Considerando que as áreas urbanas não foram mapeadas, devido à mistura constante com as demais classes.

Num sistema de classificação de alvos é essencial que se possam extrair características precisas destes, com a intenção de potencializar os acertos do sistema. A análise orientada a objeto de imagens é uma alternativa desafiadora para a visão computacional e de grande potencial na análise de imagens de alta resolução espacial.

Neste contexto, a busca de um classificador de imagens onde o conhecimento do interprete é considerado, torna-se uma alternativa promissora, uma vez que propõem suprimir a dificuldades existentes nos classificadores automáticos. Portanto, a utilização da análise orientada a objetos pode facilitar a identificação e monitoramento das áreas de preservação permanente, servindo de ferramenta na tomada de decisões dos órgãos fiscalizadores e licenciadores.

3.4 Testes estatísticos

O índice *kappa* proposto por Landis e Koch (1977) considera toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação. Para obter o índice *Kappa* é necessária a utilização da seguinte equação (2):

$$k = \frac{N \sum X_{ii} - \sum X_{i+} X_{+i}}{N^2 - \sum X_{i+} X_{+i}} \quad (2)$$

Em que:

k = Índice *Kappa* de concordância;

N = número de observações (Referências de campo);

X_{ii} = observações na linha i e coluna i (diagonal principal);

X_{i+} = total marginal da linha i;

X_{+i} = total marginal da coluna i.

Para conceituar os resultados obtidos pelo coeficiente *Kappa*, foram utilizados intervalos definidos por Landis e Koch (1977) como mostra a Tabela 3.

Tabela 3: Índice *Kappa*

VALOR DE <i>KAPPA</i>	QUALIDADE DA CLASSIFICAÇÃO
< 0,0	Péssima
0,0 – 0,2	Ruim
0,2 – 0,4	Razoável
0,4 – 0,6	Boa
0,6 – 0,8	Muito boa
0,8 – 1,0	Excelente

Fonte: Landis e Kock (1977).

A Exatidão Global é obtida dividindo o somatório dos *pixels* classificados corretamente contidos na diagonal principal pelo número total de *pixels* com o resultado em porcentagem de acertos, e o mínimo aceito para mapas de uso é de 85% (JENSEN, 1996). A exatidão global (*eg*) e a razão entre a soma de todos os elementos classificados corretamente pelo número total de elementos. Esta medida é calculada pela equação (3):

$$eg = \frac{\sum_{i=1}^r x_{ii}}{n} \quad (3)$$

Em que:

x_{ii} = Elementos da diagonal principal;

r = Número de classes;

n = Número total de amostras.

A acurácia do usuário é calculada dividindo o número total de *pixels* corretamente classificados em uma classe pelo número total de *pixels* classificados nessa classe e refere-se aos erros de comissão a partir da probabilidade que um *pixel* classificado na imagem tem de representar a classe no campo, onde para Ferreira, Dantas e Morais (2007), a comissão se refere à delimitação excessiva de determinada classe.

A acurácia do usuário (*au*) é expressa pela razão do número de elementos classificados corretamente em uma classe pelo número total de elementos classificados na mesma. Esta medida reflete os erros de comissão da classificação e indica a probabilidade de um elemento classificado em uma determinada categoria realmente pertencer a mesma (LILLESAND; KIEFER; CHIPMAN, 2004). É calculada segundo a equação (4):

$$au = \frac{x_{ii}}{x_{i+}} \quad (4)$$

Em que:

x_{ii} = Número de elementos classificados corretamente.

x_{i+} = Total de elementos classificados para uma categoria i .

A acurácia do produtor é calculada dividindo o número total de *pixels* corretamente classificados em uma classe pelo número total de *pixels* desta classe, indicado na referência de campo. Para Suarez e Candeias (2012), a acurácia do produtor se refere aos erros de omissão, sendo a probabilidade de um *pixel* de referência ser corretamente classificado. Ainda segundo Ferreira, Dantas e Morais (2007), a omissão se refere a uma imperfeita definição de determinada classe.

A acurácia do produtor (ap) é a razão entre o número de elementos classificados corretamente em uma determinada categoria pelo número de elementos de referência amostrados para a mesma categoria (LILLESAND; KIEFER; CHIPMAN, 2004). Esta medida reflete os erros de omissão da classificação sendo expressa pela equação (5):

$$ap = \frac{x_{ii}}{x_{+i}} \quad (5)$$

Em que:

x_{ii} = Número de elementos classificados corretamente;

x_{+i} = Total de elementos de referência amostrados para uma categoria i .

4. MATERIAL E MÉTODOS

4.1 Área de estudo

A bacia do Rio Grande, pertence à bacia do Alto Rio Paraná, ocupa uma área de aproximadamente 143.000 km², sendo que 86.500 km² pertencem ao Estado de Minas Gerais. O Rio Grande nasce na serra da Mantiqueira e percorre 1.300 km até a área de confluência com o rio Paranaíba, onde juntos dão origem ao rio Paraná (COMPANHIA ENERGÉTICA DE MINAS GERAIS, 2000).

No Alto Rio Grande, à montante do reservatório de Furnas, estão localizadas as Usinas Hidrelétricas de Funil, Itutinga e Camargos. A Hidrelétrica de Camargos está localizada cerca de 5 km a montante do reservatório de Itutinga e este, aproximadamente a 45 km à montante do reservatório de Funil. O rio Capivari e o rio das Mortes são dois importantes afluentes do rio Grande e seus volumes de água ajudam na formação do reservatório do Funil.

A UHE Funil está localizada em uma área com relevo ondulado e sua vegetação dominante é a transição entre a Mata Atlântica e o Cerrado. Há também campo cerrado tropical nos locais de domínio de solos mais rasos, campo rupestre nos níveis superiores das serras de altitudes superiores a 1.000 m e o campo hidrófilo de várzeas nas baixadas (FERREIRA, 2005). De acordo com a classificação de Köppen, o clima da região é do tipo Cwb (tropical de altitude).

A área de estudo foi delimitada pela área descrita como área de entorno da UHE Funil como demonstrado na Figura 1, uma vez que o intuito da aquisição da imagem foi de realizar estudos e cadastros na área de influência do reservatório.

A definição de área de entorno de reservatórios está estipulada no Plano Ambiental de Conservação e Uso do Entorno de Reservatório Artificial (PACUERA, 2011), que define área de entorno como área de contribuição

direta, ou seja, as encostas voltadas diretamente para o reservatório, que fisicamente interferem de forma direta na conservação da qualidade das águas.

Este é o espaço onde ocorrem, ou poderão ocorrer, usos múltiplos, diretamente influenciados pelas características físicas, pela dinâmica demográfica e pelos eventuais rebatimentos dos processos socioeconômicos, decorrentes da implantação do empreendimento e da conseqüente alteração da paisagem. Esta área, embora não inundada, guarda relação estreita com o reservatório, podendo ser por ele afetada, é delimitada por uma linha imaginária que interliga as cristas marginais, paralela à cota de inundação. Esta linha de cristas marginais corresponde aos divisores das microbacias de contribuição direta do rio Grande (PACUERA, 2011).

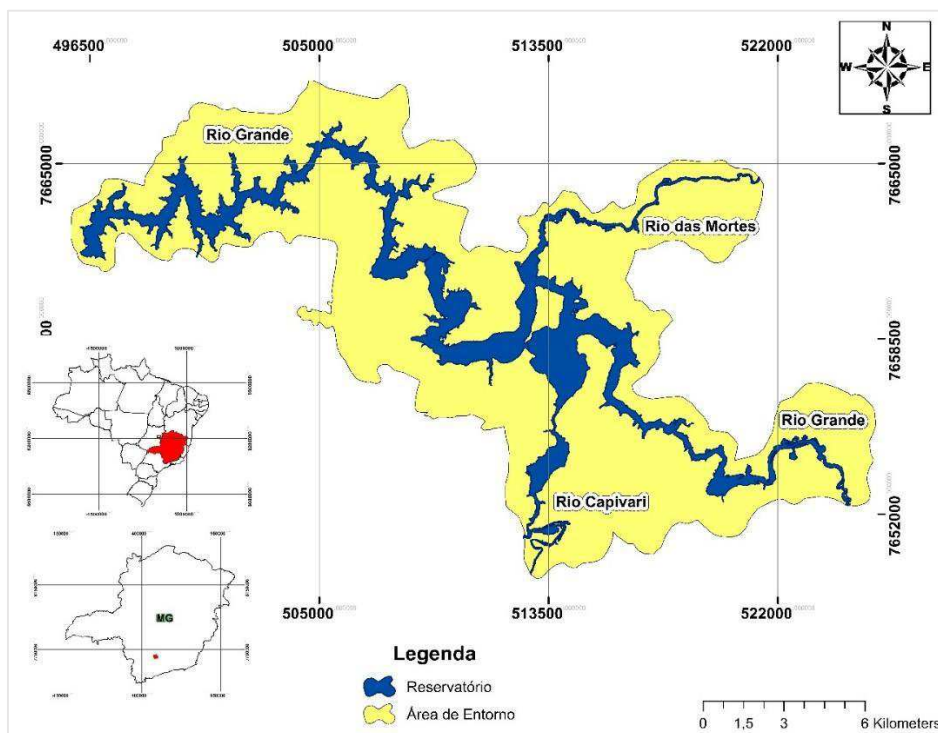


Figura 1: Reservatório da Usina Hidrelétrica do Funil e área de entorno.

4.2 Material

4.2.1 Imagem QUICKBIRD

O presente estudo utilizou duas imagens adquiridas pela empresa UHE Funil, que disponibilizou a mesma para o estudo.

O produto fornecido é um mosaico de imagens de satélite QUICKBIRD, ortoretificada com data de 30/07/2009 e 17/08/2009, contendo três bandas multiespectrais com 2,44 m de resolução espacial e uma pancromática com 0,61 m, conforme indica Tabela 4. Essas bandas foram fusionadas com a banda pancromática gerando uma imagem com resolução espacial de 0,61 metros e resolução radiométrica de 8bits.

As imagens mosaicadas possuem uma área de 470 km² e foram recortadas para separar a área do entorno do reservatório, contudo esse recorte resultou em uma perda da parte superior da área de entorno na imagem final.

Tabela 4: Bandas do satélite QUICKBIRD

BANDA	FAIXA ESPECTRAL (μ)	RESOLUÇÃO ESPACIAL(m)
Banda do azul	450 – 520	2,44
Banda do verde	520 – 600	2,44
Banda do vermelho	630 – 690	2,44
Banda do Pancromático	405 – 1053	0,61

4.2.2 Softwares

Os *softwares* utilizados nas diferentes etapas do estudo foram:

- ArcGis 10.2® para elaboração do mapa de referência (classificação visual da imagem) com os uso e ocupação da área do entorno UHF e para a confecção final dos mapas;

- Envi 4.8® para classificação supervisionada pelo método *Maximum likelihood* e para geração da matriz de confusão e a partir dela obter o índice *kappa*, exatidão global, acurácia do usuário e acurácia do produtor;
- Envi EX® para realizar o processo de análise de imagem baseada em objeto.

4.3 Etapas

Dentre as etapas de execução do projeto estão: levantamento de dados; agrupamento de informações; segmentação da imagem; classificações das imagens e análise estatística dos resultados conforme fluxograma apresentando na Figura 2.

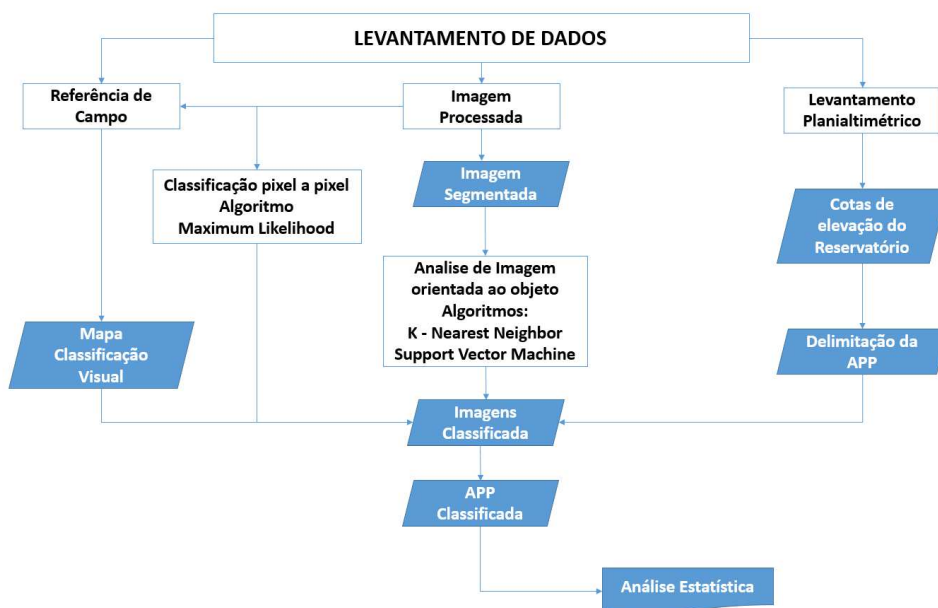


Figura 2: Fluxograma da metodologia utilizada.

4.3.1 Levantamento de dados

4.3.1.1 Levantamento Planialtimétrico

O levantamento planialtimétrico foi disponibilizado pela UHE Funil para realização deste estudo.

Para o levantamento foram utilizados equipamentos do tipo GNSS (*Global Navigation Satellite System*) TRIMBLE R6, os quais representam a mais moderna tecnologia de posicionamento (utiliza a constelação de satélites americanos – NAVSTAR*global positioning system*(GPS) e a constelação de satélites russos – GLONASS), aumentando assim a precisão e a confiabilidade dos dados levantados. Os equipamentos contam com um sistema de correção por rádio em tempo real (Real Time Kinematic - RTK) que permite a verificação instantânea dos dados levantados, bem como a determinação de linhas divisórias importantes como cotas de inundação de reservatórios, ou linhas demarcatórias já certificadas junto ao INCRA (Instituto Nacional de Colonização e Reforma Agrária).

O transporte de coordenadas foi feito a partir das bases homologadas pelo IBGE (Instituto Brasileiro de Geografia e Estatística), utilizando equipamento GPS geodésico de dupla frequência, com suporte da rede brasileira de monitoramento contínuo.

A partir do levantamento planialtimétrico do reservatório da UHE Funil foi definida a área de APP, resultante das cotas normal de operação (808,00 metros) e da cota máximo maximorum (810,70 metros), gerando um perímetro de 364 km.

4.3.1.2 Referência de Campo

Para criação do mapa de referência de campo foi utilizado a classificação visual, com correções de campo em áreas do levantamento consideradas duvidosas no decorrer da classificação. Na área de estudo foram discriminados seis tipos de uso do solo, classificados em: “corpos d’água”; “Uso antrópico”, “pastagem”; “vegetação natural”; “solo exposto” e “culturas”. Levando em consideração a boa qualidade da imagem não foi identificada qualquer presença de nuvens.

4.3.1.3 Classificação *Maximum Likelihood*

Para a classificação utilizando o algoritmo *Maximum likelihood* no software ENVI 4.8, foram coletadas amostras de 200 pixels para cada classe de uso do solo, estes representam $7,6 \times 10^8$ % da área total. No estudo foram consideradas as classes: “corpos d’água”; “Uso antrópico”, “pastagem”; “vegetação natural”; “solo exposto” e “culturas”, neste classificador apenas a informação espectral de cada pixel é utilizada para classificar imagens.

4.3.1.4 Análise orientada a objeto

Neste procedimento foram realizadas a segmentação e a classificação orientada a objetos utilizando as três bandas do visível fusionadas com a pancromática do satélite QUICKBIRD, processadas com o *software* ENVI EX.

4.3.1.5 Segmentação

A segmentação foi realizada no *software* ENVI EX 4.8® que é um processo que particiona a imagem, subdividindo-a, cujo nível de detalhe está associado à detecção de objetos e regiões de interesse. O processo de segmentação por extração de características utilizado no *software* é baseado

no algoritmo que simula uma bacia hidrográfica por imersão, o chamado *watershedsbyimmersion* (CAMPOS et al., 2013; VINCENT; SOILLE, 1991). O *software* ENVI EX utiliza esse algoritmo para segmentar imagens. O passo inicial é a extração de características da imagem, a partir da ferramenta *feature extraction*. Este recurso utiliza uma abordagem baseada em objetos para segmentar imagens, definidos a partir de uma região de interesse com características espaciais, espectrais (brilho e cor) e texturais que definem a região (AGUIRRE-GUTIÉRREZ; SEIJMONSBERGEN; DUIVENVOORDEN, 2012; BLASCHKE, 2010; YAN et al., 2006). O *software* ENVI EX emprega um algoritmo de segmentação baseado no conhecimento e requer apenas um parâmetro de entrada, nível de escala, onde se define a similaridade dos *pixels*. Escolhendo um alto nível de escala, menos segmentos são definidos, já em uma escala de baixo nível, surgem mais segmentos a serem definidos, ou seja, numa escala de 0 a 100, 0 se refere a uma supersegmentação e 100 a nenhuma segmentação. Em seguida, foi realizada a fusão de segmentos por meio da ferramenta *merge*. Essa ferramenta é utilizada para agregar pequenos segmentos dentro de grandes áreas. O parâmetro *merge* ou nível de fusão varia de 0 a 100, onde há a fusão de segmentos adjacentes com base em uma combinação de informação espacial e espectral. Estes valores, atribuídos ao nível de escala e fusão, foram definidos com base na pré-visualização disponibilizada pelo *software*.

Os valores utilizados foram alcançados por meio de tentativas e repetições na busca de encontrar os melhores resultados, para este trabalho o valor de *merge* utilizado foi de 90% e o nível de escala na segmentação foi de 40%.

Na etapa seguinte, houve a opção de refinar os resultados obtidos a partir da ferramenta *thresholding*, onde sua utilização é recomendada quando os objetos de interesse possuem um alto contraste em relação ao restante da imagem. Este procedimento facilita a segmentação e posterior extração das feições. Seguindo este critério, para este trabalho a ferramenta *thresholding* não foi adotada.

4.3.1.6 Classificação utilizando *K-nearest neighbor* e *Support vector machine*

Para a classificação foram coletadas amostras de vegetação natural, pastagem, solo exposto e cultivo e uso antrópico. Coletadas as amostras, todos os parâmetros disponibilizados pelo *software* ENVI EX para os atributos; espacial, textura, espectral e customizado, descritos a seguir, foram considerados:

- Espacial: área (area), comprimento (length), compactidade (compact), convexidade (convexity), solidez (solidity), arredondamento (roundness), fator forma (formfactor), alongamento (elongation), medida do retângulo (rect_fit), direção principal (maindir), comprimento do eixo maior (majaxislen), comprimento do eixo menor (minaxislen), número de orifícios do polígono (numholes) e área total do polígono da zona de contorno externo (holesolrat);
- Textura: distância da textura (tx_range), média da textura (tx_mean), variância da textura (tx_variance), entropia da textura (tx_entropy);
- Espectral: valor mínimo dos *pixels* que compõem as bandas 1, 2 e 3, valor máximo dos *pixels* que compõem as bandas 1, 2 e 3, valor médio dos *pixels* que compõem as bandas 1, 2 e 3 e valor do desvio padrão dos *pixels* que compõem as bandas 1, 2 e 3.

Com a finalidade de extrair informações e reconhecer padrões e objetos homogêneos, foram adotados os métodos de classificação supervisionada disponíveis pelo *software*, sendo: *K-nearest neighbor* e *Support vector machine*.

O algoritmo de classificação baseado no *K-nearest neighbor* é uma técnica empregada no reconhecimento de padrões onde o *software* exige a seleção de valores para o parâmetro k, sendo este o número de vizinhos considerados durante a classificação (XU et al., 2013). Foram testados os valores 1, 3, 5 e 7 (só é possível utilizar valores ímpares) para o parâmetro K

- representa o número de vizinhos testados na classificação - sendo selecionado o valor 1 por apresentar melhores resultados.

O algoritmo *Support vector machine*, determina-se limites de decisão para a separação das classes bem como a minimização dos erros (MOUNTRAKIS; JUNGHOIM, 2010). Foi selecionada a função *kernel radial basis*, recomendado por Pereira et al. (2011) e Roza e Ribeiro (2013). Os valores *gamma* e parâmetro de penalidade foram 0,03 e 100, valores padrões sugeridos pelo *software*.

4.3.1.7 Estatística

Posterior às classificações utilizando os algoritmos *K-nearest neighbor* e *Support vector machine* e o algoritmo *Maximum likelihood*, houve a pós-classificação, ou seja, a comparação das imagens resultantes classificadas com os dados oriundos do mapa de referência para análise da exatidão.

Na pós-classificação avaliou-se a exatidão das classificações a partir da matriz de confusão tendo como resultado as seguintes análises: índice *kappa*, exatidão global, acurácia do usuário e acurácia do produtor.

5. RESULTADOSE DISCUSSÃO

5.1 Mapa referência

O Mapa de referência de campo apresentado na Figura 3 foi utilizado como apoio na averiguação da acurácia do mapeamento realizado para a APP.

Foram identificadas oito classes de uso do solo conforme apresentado na Tabela 5 sendo, 13.107,67 ha da classe “pastagem”, 3.792,98 ha da classe “vegetação natural”, 2.817,97 ha da classe “cultivo”, 573,53 ha da classe “corpos d’água”, 349,85 ha da classe “uso antrópico”, 345,01 ha da classe “solo exposto”, 170,67 ha da classe “mineração” e 38,23 ha da classe “aflorentamento rochoso”.

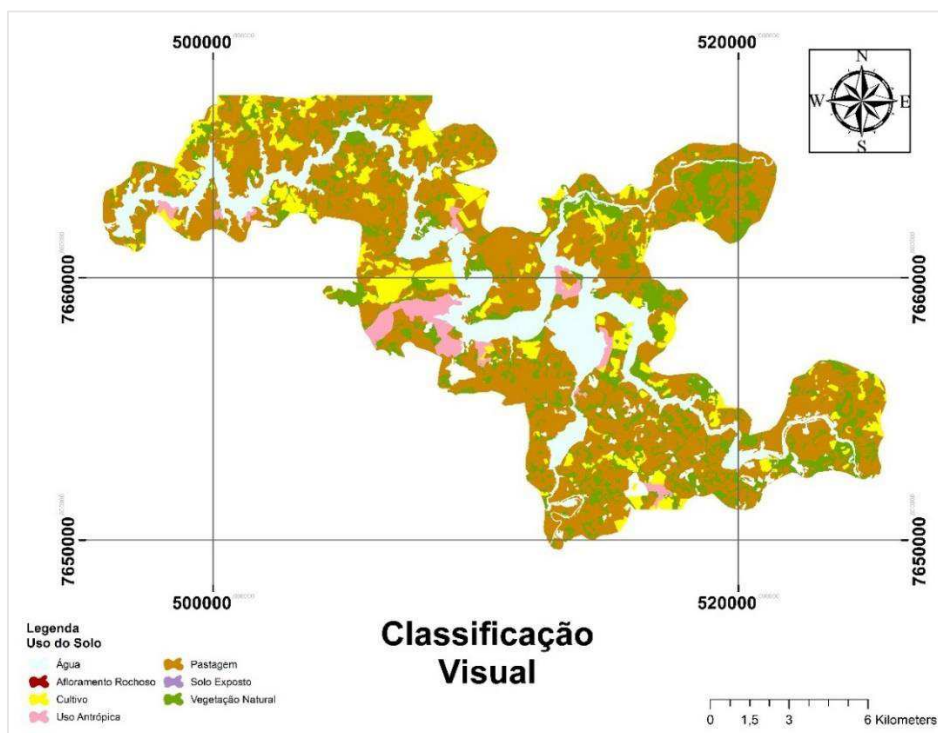


Figura 3: Mapa de referência dos usos na área de entorno do reservatório da UHE Funil

Tabela 5: Quantificação da área de entorno classificada visualmente.

Classe	Área Classificada (ha)	Área Classificada (%)
Pastagem	13.107,67	61,84
Vegetação natural	3.792,98	17,89
Cultivo	2.817,97	13,29
Corpos d'água	573,53	2,70
Uso antrópica	349,85	1,65
Solo exposto	345,07	1,62
Mineração	170,67	0,79
Afloramento Rochoso	38,23	0,22
Total	21.195,99	100

5.2 Área mínima mapeada

Considerando as características da imagem de satélite que foi utilizada, essa possui a menor dimensão legível um *pixel* de 0,36m². A relação entre a menor área mapeada e a área real do terreno que está vinculada à escala de mapeamento 1:10.000, portanto, nesta imagem a menor área mapeável será equivalente a 0,3600 ha.

5.3 Classificação de imagens

Para discriminar os tipos de uso do solo nas APP, houve uma comparação entre três métodos de classificadores supervisionados e a classificação visual.

5.3.1 Classificação visual da APP da UHE Funil

A Figura 4 apresenta a área de interesse que contempla as cotas de operação da UHE Funil que é considerada como APP, onde foram identificadas, na área de 1043 ha, cinco classes de uso do solo conforme

Tabela 6, sendo 631,9302 ha da classe “pastagem”; 294,76 ha da classe “vegetação natural”; 47,78 ha da classe “cultivo”; 45,40 ha da classe “solo exposto” e 23,59 ha da classe “uso antrópico”.

A identificação das classes por meio da classificação visual contíguo as verificações de campo serviu de norteador para criação do mapa referência de campo que foi utilizado para a análise da veracidade dos classificadores. Em diversos estudos a utilização da classificação visual é tomada como referência de campo e também como o meio mais confiável de identificar classes em uma área.

Serigatto (2006) em seus estudos sobre mapeamento de uso da terra em APP e identificação dos conflitos de uso da terra na bacia hidrográfica do rio Sepotuba-MT, utilizando classificação visual encontrou como uso nas áreas de preservação as seguintes classes de uso, 38,65% de classe Agropastoril, 23,26% da classe Floresta Nativa, 22,31% da classe Cerrado, 15,32% de classe Campo Limpo e 0,46% da classe Água. Estes valores foram monitorados e por utilizar a classificação visual, ao realizar o estudo em série temporal obtiveram excelentes parâmetros da mudança no uso do solo nestas áreas. Oliveira e Chaves (2007) utilizando sensores de média e alta resolução espacial com o intuito de caracterização geomorfológica no raso da Catarina-BA, empregando a análise visual feita com a imagem QUICKBIRD constatou-se que se trata de uma área de vegetação de caatinga espaçada, contudo visualizaram-se níveis diferenciados de adensamento da vegetação nesta unidade, à medida que aumenta as cotas altimétricas e conseqüentemente o relevo se torna mais plano, atingindo 0° a caatingas se torna um pouco mais densa. Cintra (2007) realizou estudos de classificação de estágios sucessionais florestais no Parque Estadual da Pedra Branca, RJ, por meio de imagem do sensor IKONOS, utilizando a estratégia de classificação por hierarquia de classes, mostrou-se um método adequado para interpretação visual das classes que, por ser sistemática, diminui um pouco da subjetividade do processo de classificação. Soares et al. (2011) ao mapear APP e identificar os conflitos legais de uso da terra na bacia hidrográfica do Ribeirão São

Bartolomeu-MG, que com a utilização de ortomagem de alta resolução espacial do satélite IKONOS II permitiu o mapeamento de 9 classes de cobertura e uso da terra, com destaque para a classe Pastagem, ocupando 42,70% da área total da bacia hidrográfica do Ribeirão São Bartolomeu.

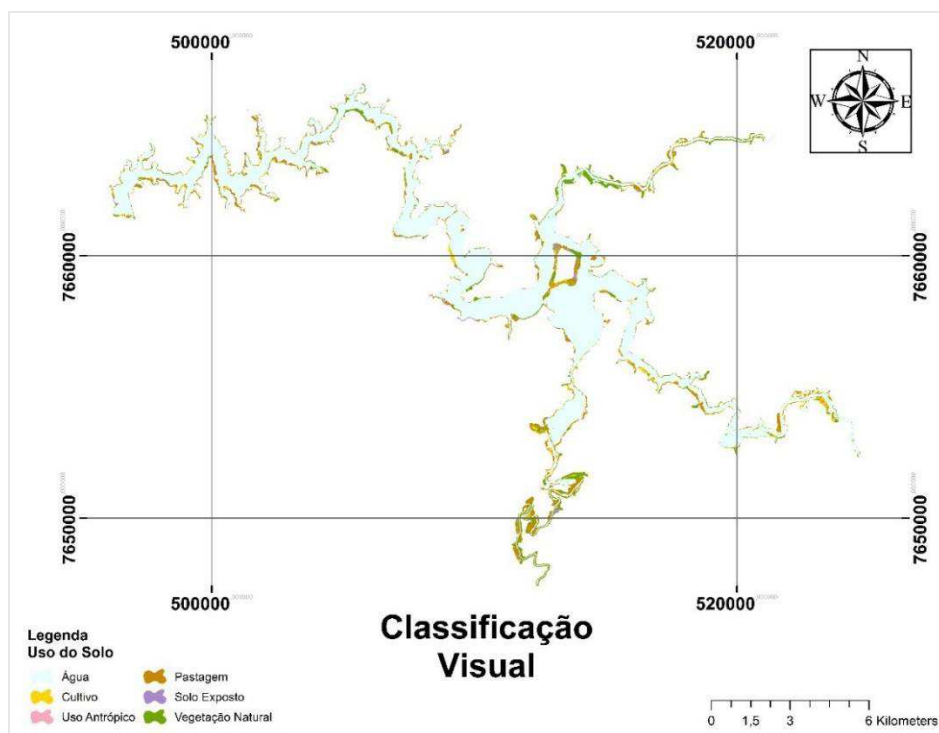


Figura 4: Mapa de classificação visual da APP da UHE Funil.

Tabela 6: Quantificação do uso do solo nas APP classificada visualmente.

Classes	Área classificada (ha)	Área classificada (%)
Pastagem	631,93	60,56
Vegetação natural	294,76	28,24
Cultivo	47,78	4,58
Solo exposto	45,40	4,35
Uso antrópico	23,59	2,27
Total	1043,48	100

5.3.2 Classificação de imagem utilizando o algoritmo *Maximum likelihood*

Pela Figura 5 é possível visualizar os resultados obtidos a partir do algoritmo classificador *Maximum likelihood*, onde foram encontradas cinco classes que discriminam o uso do solo, conforme observado na Tabela 7. Estas classes quantificaram valores de área de 562,93 ha da classe “pastagem”, 304,16 ha da classe “vegetação natural”, 107,77 ha da classe “cultivo”, 44,01 ha da classe “solo exposto” e 24,59 da classe “uso antrópico”.




Figura 5: Mapa da classificação de imagem utilizando o algoritmo *Maximum likelihood*

Tabela 7: Quantificação do uso do solo nas APP utilizando o algoritmo *Maximum likelihood*

Classe	Área classificada (ha)	Área classificada (%)
Pastagem	501,63	48,07
Vegetação Natural	376,46	36,07
Cultivo	35,02	3,35
Solo Exposto	82,10	7,86
Uso Antrópico	48,27	4,62
Total	1043,48	100

Analisando os dados do algoritmo *Maximum likelihood* na classificação do uso do solo nas APP do reservatório da UHE Funil, o índice *kappa* obtido mostrou a eficiência da classificação, alcançando um coeficiente *kappa* “Muito Boa” (0,68) de acordo com Landis e Kock (1977) e um índice de exatidão global de 79,89%. Bolfe et al. (2004) ao realizar classificações supervisionadas utilizando o método *Maximum likelihood* na tentativa de quantificar povoamentos diferenciados de três classes diferentes de vegetação, alcançaram índices *kappa* de 0,84 e exatidão global 85,23%. Os autores concluíram que o índice *kappa* demonstrou consistência na avaliação da acurácia de mapeamentos produzidos pelo método *Maximum likelihood*.

De acordo com a matriz de confusão, gerada a partir da classificação *Maximum likeliho*, apresentada na Tabela 8, tem-se classe “Vegetação natural” apresentou confusão de 59,19% com a classe “Cultivo” e 1,12% com a classe “Pastagem”; a classe “Pastagem” apresentou confusão de 2,67% com a classe “Cultivo” e 0,14% com a classe “Vegetação natural”; a classe “Cultivo” apresentou confusão de 25,11% com a classe “Vegetação natural” e 32,42% com a classe “Pastagem”; a classe “Uso antrópico” apresentou confusão de 27,54% com a classe “Solo exposto”, 9% com a classe “Cultivo”, 2,11% com a classe “Pastagem” e 0,03% com a classe “Vegetação natural”; a classe “Solo exposto” apresentou confusão de 97,12% com a classe “Uso antrópico” e 0,05% com a classe “Pastagem”.

Tabela 8: Matriz de confusão utilizando o algoritmo *Maximum likelihood*.

Classificação	Referências de campo (%)				
	Vegetação natural	Pastagem	Cultivo	Uso antrópico	Solo exposto
Vegetação natural	74,72	1,12	59,19	0,00	0,00
Pastagem	0,14	64,30	2,67	0,00	0,00
Cultivo	25,11	32,42	29,14	0,00	0,00
Uso antrópico	0,03	2,11	9,00	2,88	27,54
Solo exposto	0,00	0,05	0,00	97,12	72,46
Total	100,00	100,00	100,00	100,00	100,00

A Tabela 9 apresenta os resultados obtidos por meio do classificador *Maximum likelihood*, verifica-se pelos resultados que a acurácia do usuário, ou seja, a probabilidade de representação das classes no campo para “Vegetação natural”, “Pastagem”, “Cultivo”, “Uso antrópico” e “Solo exposto” apresentaram respectivamente 74,15%, 97,99%, 13,54%, 1,21% e 69,10%. Já a acurácia do produtor indica que as mesmas classes apresentam 73,74%, 64,30%, 29,09%, 2,88%, 72,46% de probabilidade de terem sido classificadas de acordo com as referências de campo.

Tabela 9: Acurácia do usuário e acurácia do produtor.

Classes	<i>Maximum likelihood</i>	
	Acurácia do Usuário(%)	Acurácia do Produtor(%)
Vegetação natural	74,15	73,74
Pastagem	97,99	64,30
Cultivo	13,54	29,09
Uso antrópico	1,21	2,88
Solo exposto	69,10	72,46

O Gráfico 1 apresenta a comparação do algoritmo *Maximum likelihood* com a classificação visual, onde observa-se que a classificação obteve alguns dados discrepantes quando comparados com o mapa de referência, principalmente nas classes com áreas significativamente maiores. As classes “Vegetação natural”, “Solo exposto” e “Uso antrópico” foram superestimada, já a classe “Pastagem” e “Cultivo” foram subestimada.




Gráfico 1: Quantificação do mapa de referência e da classificação utilizando algoritmo *K-nearest neighbor*.

5.3.3 Classificação da imagem utilizando o algoritmo *K-nearest neighbor*

Pela Figura 6 é possível visualizar os resultados obtidos a partir do algoritmo classificador *K-nearest neighbor*, onde foram encontradas cinco classes que discriminam o uso do solo, conforme observado na Tabela 10. Estas classes quantificaram valores de área de 562,9327 ha para a classe “pastagem”, 304,1596 ha para a classe “vegetação natural”, 107,7757 ha para a classe “cultivo”, 44,0180 para a classe “solo exposto” e 24,5970 para a classe “uso antrópico”.

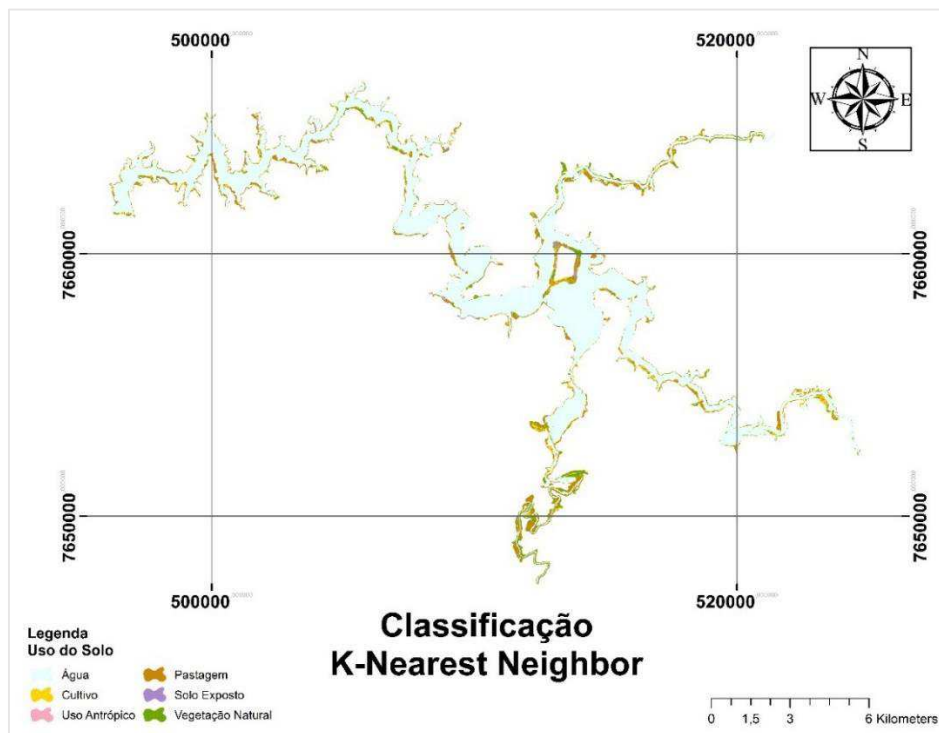


Figura 6: Mapa da análise orientada a objeto utilizando o algoritmo *K-nearest neighbor*

Tabela 10: Quantificação do uso do nas APP utilizando o algoritmo *K-nearest neighbor*.

Classe	Área classificada (ha)	Área classificada (%)
Pastagem	562,93	53,94
Vegetação Natural	344,16	29,14
Cultivo	107,77	10,32
Solo Exposto	44,01	4,21
Uso Antrópico	24,59	3,35
Total	1043,48	100

No presente trabalho, o índice *kappa* visando analisar a discriminação das classes do uso do solo utilizando o algoritmo classificado *K-nearest neighbor* mostrou a eficiência da classificação, alcançando um coeficiente *kappa* “Excelente” (0,88) de acordo com Landis e Kock (1977) e um índice de exatidão global de 91,40%. Em estudos realizados por Campos et al. (2013), onde analisaram o uso e ocupação do solo na região de Rio Acima - MG, compararam métodos de classificação baseada em objeto onde testaram a eficiência de dois algoritmos (*Bhattacharya* e *K-nearest neighbor*) em *software* diferentes (SPRING 5.2 e ENVI EX) respectivamente. A acurácia do algoritmo *Bhattacharya* foi de 87,5% e do algoritmo *K-nearestneighbor* 86,8%. No entanto, foi ressaltado pelos autores que apesar do algoritmo *K-nearest neighbor* ter apresentado uma acurácia da classificação ligeiramente inferior, ele foi o que melhor descreveu a dinâmica ambiental da região de estudo. Fernandes, Nunes e Silva (2012) utilizando imagens do sensor LANDSAT/TM, classificação orientada a objeto e o algoritmo *K-nearest neighbor* para caracterizar o uso e cobertura do solo na região do Médio Araguaia obtiveram para a classificação índice de exatidão global de 83,3% e um índice *Kappa* de 0,72, os autores descrevem como satisfatória e promissora na utilização no delineamento para classes de uso e cobertura do solo.

De acordo com a matriz de confusão apresentada na Tabela 11 analisada pelo algoritmo de classificação *K-nearest neighbor* a classe

“Vegetação natural” apresentou confusão de 4,81% com a classe “Cultivo” e 0,31% com a classe “Pastagem”; a classe “Pastagem” apresentou confusão de 8,29% com a classe “Vegetação natural”, 7,65% com a classe “Uso antrópico”, 4,18% com a classe “Cultivo” e 1,12% com a classe “Solo exposto”; a classe “Cultivo” apresentou confusão de 4,03% com a classe “Vegetação natural”, 3,58% com a classe “solo exposto”; 1,06% com a classe “Uso antrópico” e 0,03% com a classe “Pastagem”; a classe “uso antrópico” apresentou confusão de 2,83% com a classe “Solo exposto”, 1,06% com a classe “Cultivo”, 0,81% com a classe “Vegetação natural” e 0,31% com a classe “Pastagem” e a classe solo exposto apresentou confusão de 0,25% com a classe ‘uso antrópico’.

Dentre as principais confusões entre as classes, podemos citar a “Vegetação natural” com “Cultivo” que é justificada pela dificuldade de se identificar um atributo de natureza espectral que as diferencie, principalmente no caso do cultivo de uma cultura perene em produção, como ocorre com os plantios de café, que na área de estudo são muito comuns. Um outro destaque foi na confusão apresentada pela classe de Solo exposto com e Uso antrópico, este mesmo tipo de mistura também foi encontrado no trabalho de Thomas, Hendrix e Congalton (2003). Esta dificuldade de distinção entre as duas classes é em virtude da predominância de argila na composição tanto das telhas cerâmicas quanto do solo exposto, o que produz uma resposta espectral muito semelhante por parte desses alvos.

Tabela 11: Matriz de confusão utilizando o algoritmo *K-nearest neighbor*.

Classificação	Referências de campo (%)				
	Vegetação natural	Pastagem	Cultivo	Uso antrópico	Solo exposto
Vegetação natural	85,90	0,31	4,81	0,00	0,03
Pastagem	8,29	99,36	4,18	7,65	1,12
Cultivo	4,03	0,03	89,31	1,06	3,58
Uso antrópico	0,81	0,31	1,06	90,96	2,83
Solo exposto	0,00	0,00	0,00	0,25	92,31
Total	100,00	100,00	100,00	100,00	100,00

A Tabela 12 apresenta os resultados obtidos por meio do classificador *K-nearest neighbor*, verificasse pelos resultados que a acurácia do usuário, ou seja, a probabilidade de representação das classes no campo para “Vegetação natural”, “Pastagem”, “Cultivo”, “Uso antrópico” e “Solo exposto” apresentaram respectivamente 98,16%, 83,78%, 78,73%, 93,20% e 99,80%. Já a acurácia do produtor indica que as mesmas classes apresentam 85,90%, 99,36%, 89,31%, 90,96%, 92,31% de probabilidade de terem sido classificadas de acordo com os dados de referência.

Tabela 12: Acurácia do usuário e acurácia do produtor.

Classes	<i>K-nearest neighbor</i>	
	Acurácia do Usuário (%)	Acurácia do Produtor (%)
Vegetação natural	98,16	85,90
Pastagem	83,78	99,36
Cultivo	78,73	89,31
Uso antrópico	93,20	90,96
Solo exposto	99,80	92,31

O Gráfico 2 apresenta a comparação do algoritmo *K-nearest neighbor* com a classificação visual, onde observa-se que a classificação se aproximou consideravelmente do mapa de referência, principalmente nas classes com áreas significativamente maiores, as classes “Vegetação natural” e “Cultivo” foram superestimada, já a classe “Pastagem” foi subestimada. Marujo et al. (2013) objetivando identificar melhor método de classificação para cultivos cafeeiros em imagens de alta resolução espacial obtiveram os melhores resultados com a utilização do algoritmo *K-nearest neighbor* com resultados de índice global de 87,53% e índice *kappa* de 0,80, tendo recomendado em suas conclusões o uso de classificação orientada a objeto em imagem de alta resolução espacial. Gao et al. (2007) em seus estudos utilizando classificação orientada a objeto em imagens LANDSAT ETM+ em diferentes algoritmos

de classificação e obteve como melhor resultado o mapeamento utilizando o algoritmo *K-nearest neighbor* quando comparado com o classificador *Maximum likelihood*, pois conseguiu superar os efeitos do *salt and pepper*, e atingir uma exatidão global de 80,59% comparado com os 75,99% do classificador *pixel a pixel*, valores próximos aos encontrados no presente trabalho. Os autores ressaltaram também a utilização de ferramentas de pós-classificação para atingir melhores resultados no processo de pós-classificação.

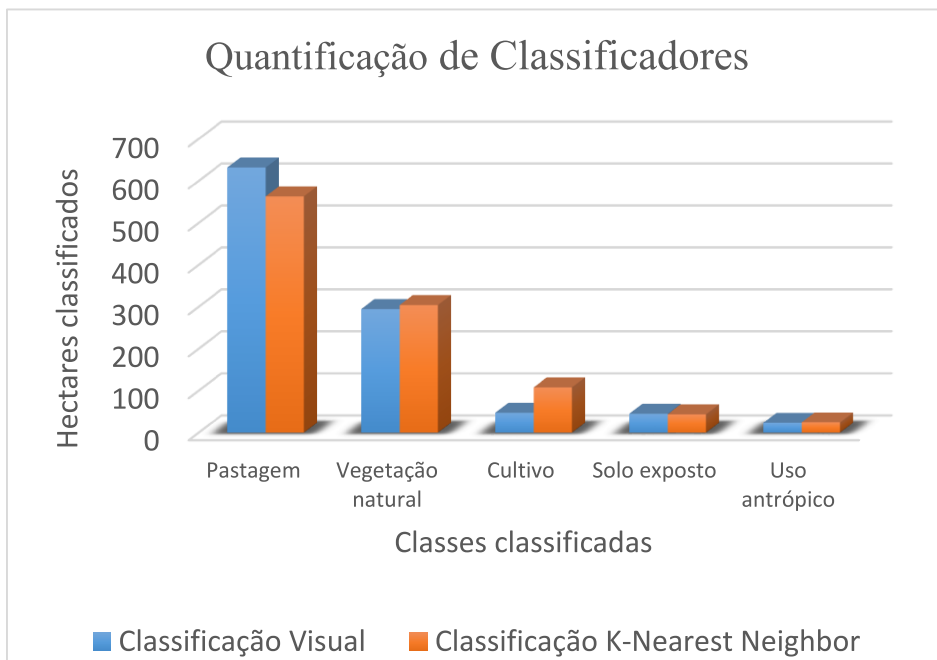


Gráfico 2: Quantificação do mapa de referência e da classificação utilizando algoritmo *K-nearest neighbor*

5.3.4 Análise orientada á objeto utilizando o algoritmo *Support vector machine*

Pela Figura 7 é possível visualizar os resultados obtidos a partir do algoritmo classificador *Support vector machine*, onde foram encontradas cinco classes que discriminam o uso do solo, conforme observado na Tabela

13. Os valores de área para estas classes foram de: 600,2254 ha classe “pastagem”, 256,2016 ha classe “vegetação natural”, 116,2529 ha classe “cultivo”, 57,2037 ha classe “solo exposto” e 13,5994 ha classe “uso antrópico”.

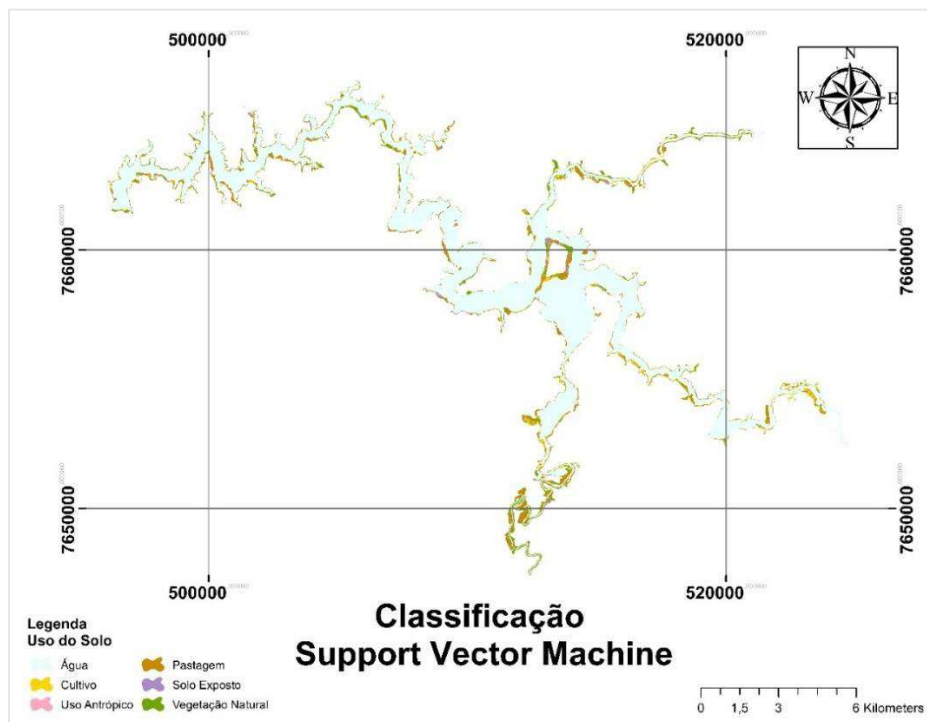


Figura 7: Mapa da Análise de imagem orientada a objeto utilizando o algoritmo *Support Vector Machine*.

Tabela 13: Quantificação do uso do solo nas APP utilizando o algoritmo *Support vector machine*

Classe	Área Classificada (ha)	Área Classificada (%)
Pastagem	600,2254	57,52
Vegetação natural	256,2016	24,55
Cultivo	116,2529	11,14
Solo exposto	57,2037	5,48
Uso antrópico	13,5994	1,30
Total	1043,4830	100,00%

Analisando os dados do algoritmo *Support vector machine* na classificação do uso do solo nas APP do reservatório da UHE Funil, o índice *kappa* obtido mostrou a eficiência da classificação, alcançando um coeficiente *kappa* “Muito Boa” (0,80) de acordo com Landis e Kock (1977) e um índice de exatidão global de 86,29%. Para testar a eficiência do algoritmo classificador *Support vector machine*, Noma, Korting e Fonseca (2013) utilizaram algoritmos classificadores na identificação do uso e ocupação da terra em áreas desmatadas no estado do Mato Grosso, onde generalizaram os usos considerando as classes agricultura e não-agricultura. A eficácia do método *Support vector machine* frente às classificações dos algoritmos Optimum Path Forest, Decision trees, Naive Bayes e *K-nearest neighbor* se mostrou superior. O algoritmo *Support vector machine* apresentou 88% de acurácia, enquanto que algoritmos *Optimum Path Forest*, *Decision trees*, *Naive Bayes* e *K-nearest neighbor* apresentaram 82%, 82%, 84% e 83%, respectivamente. Segundo os autores, esta técnica é originalmente desenvolvida para avaliar duas classes obtendo resultados satisfatórios.

De acordo com a matriz de confusão analisada na Tabela 14 sobre o algoritmo de classificação *Support vector machine* a classe “vegetação natural” apresentou confusão de 18,29% com a classe “Cultivo”, 2,66% com a classe “Pastagem”, 0,13% com a classe “Solo exposto” e 0,06% com a classe “Uso antrópico”; a classe “Pastagem” apresentou confusão de 16,66% com a classe “Cultivo”, 34,88 % com a classe “Solo exposto”, 5,12% com a classe “Vegetação nativa” e 2,54% com a classe “Uso antrópico”; a classe “Cultivo” apresentou confusão de 1,40% com a classe “Vegetação natural”, 1,18% com a classe “Pastagem”, 0,89% com a classe “Solo exposto” e 0,85% com a classe “Uso antrópico”; a classe “Uso antrópico” apresentou confusão de 4,12% com a classe “Cultivo”, 2,12% com a classe “Solo exposto”, 0,07% com a classe “Pastagem” e a classe “Solo exposto” apresentou confusão de 4,14% com a classe “Uso antrópico” e 0,23% com a classe “Cultivo”.

Tabela 14: Matriz de confusão da classificação utilizando o algoritmo *Support Vector Machine*.

Classificação	Referências de campo (%)				
	Mata	Pastagem	Cultivo	Uso antrópico	Solo exposto
Vegetação natural	93,49	2,66	18,29	0,06	0,13
Pastagem	5,12	96,08	16,66	2,54	34,88
Cultivo	1,40	1,18	59,95	0,85	0,89
Uso antrópico	0,00	0,07	4,12	92,30	2,12
Solo exposto	0,00	0,00	0,23	4,14	61,79
Total	100,00	100,00	100,00	100,00	100,00

A Tabela 15 apresenta os resultados obtidos por meio do classificador *Support vector machine* verificasse pelos resultados que a acurácia do usuário, ou seja, a probabilidade de representação das classes no campo para “Vegetação natural”, “Pastagem”, “Cultivo”, “Uso antrópico” e “Solo exposto” apresentaram respectivamente 89,21%, 82,43%, 87,28%, 87,41% e 96,71%. Já a acurácia do produtor indica que as mesmas classes apresentam 93,49%, 96,08%, 59,95%, 92,30%, 61,79%, de probabilidade de terem sido classificados de acordo com os dados de referência.

Tabela 15: Acurácia do usuário e acurácia do produtor.

Classe	<i>Support Vector Machine</i>	
	Acurácia do Usuário (%)	Acurácia do Produtor (%)
Vegetação natural	89,21	93,49
Pastagem	82,43	96,08
Cultivo	87,28	59,95
Uso antrópico	87,41	92,30
Solo exposto	96,71	61,79

O Gráfico 3 apresenta a comparação do algoritmo *Support vector machine* com a classificação Visual, onde observa-se que a classificação se aproximou consideravelmente do mapa de referência, principalmente nas classes com áreas significativamente maiores, as classes “Pastagem” e “Cultivo” foram superestimada, já a classe “Vegetação natural” foi subestimada. Myburgh e Niekerk (2013) comparando 3 classificadores, *K-nearest neighbor*, *Support vector machine* e *Maximum likelihood*, quanto a sua eficiência no mapeamento de cobertura do solo em imagens do sensor SPOT-5. Quanto ao desempenho, o melhor classificador que atingiu 87% de exatidão Global e um índice *kappa* de 0,86 foi o classificador *Support vector machine*. Contudo os autores deixam bem claro que os resultados deste estudo são de particularidades da África do Sul e que o classificador *K-nearest neighbor* não deve ser considerado como resultado negativo de classificação, pois ambos apresentaram e resultados muito próximos.




Gráfico 3: Quantificação do mapa de referência e da classificação utilizando algoritmo *Support vector machine*

5.4 Comparação entre os classificadores

Após os testes estáticos realizados sobre os algoritmos de classificação *Maximum likelihood*, *K-nearest neighbor* e *Support vector machine*, foram comparados os resultados para averiguação dos melhores valores dos índices propostos para do classificador mais indicado para a área de estudo.

5.4.1 Índice Kappa e Índice de Exatidão Global

Os valores estatísticos obtidos a partir dos classificadores são descritos na tabela 16.

Tabela 16: Valores de índice *kappa* e exatidão global para cada método de classificação analisado.

Classificações	<i>Kappa</i>	Exatidão Global
<i>K-nearest neighbor</i>	0,88 (Excelente)	91,40
<i>Support vector machine</i>	0,80 (Muito boa)	86,29
<i>Maximum likelihood</i>	0,68 (Muito boa)	79,89

Foi observado que o índice *kappa* e exatidão global resultantes da classificação por *K-nearest neighbor* foram superiores aos demais. Como mencionado, na classificação por análise de imagem orientada a objeto, onde são considerados os atributos espectral, espacial e de textura, diferente da classificação *pixel a pixel* onde o algoritmo classificador considera apenas a informação espectral. Por meio deste resultado foi constatado que o classificador baseado na análise de imagem orientada a objeto, onde são considerados os atributos espectral, espacial e de textura são consideradas, desempenha suas funções satisfatoriamente na classificação em APP.

Analisando o Gráfico 4 que demonstra os resultados obtidos por meio dos três algoritmos de classificação que contemplaram este estudo, *Maximum likelihood*, *K-nearest neighbor* e *Support vector machine*, foi observado que o classificador que em média resultou em valores mais próximos do mapa de referência foi o algoritmo *K-nearest neighbor*, sendo este também o que atingiu os melhores resultados estatísticos para índice *kappa* e exatidão global. No entanto, os demais classificadores desempenharam suas funções satisfatoriamente, com suas particularidades, levando em consideração que para discriminação de determinadas classes os demais algoritmos alcançaram valores superiores que o *K-nearest neighbor* como é o caso da classe “Pastagem” e “Solo exposto”.

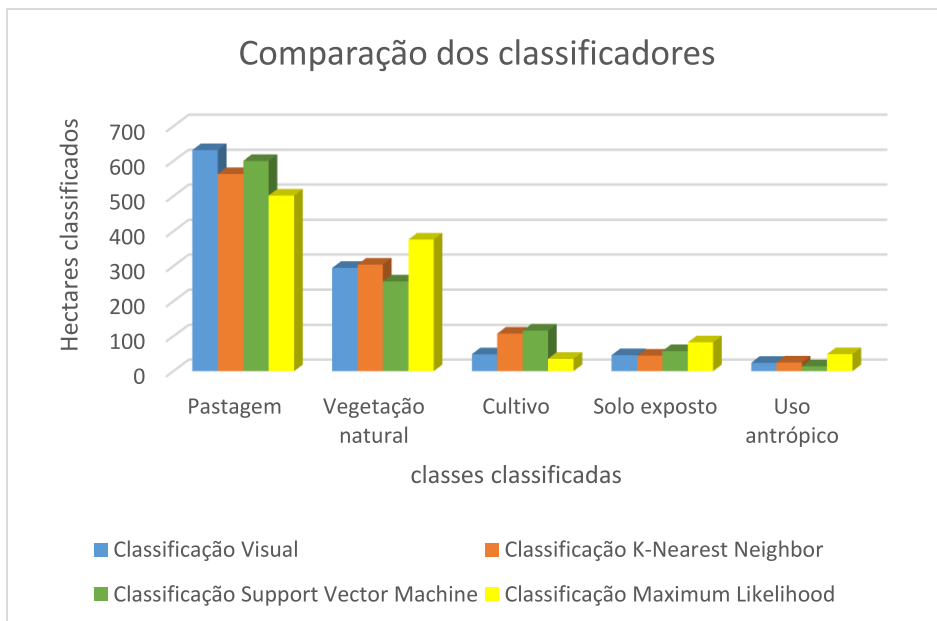


Gráfico 4: Quantificação das classes da área de estudo por meio do mapa de referência e dos algoritmos de classificação *K-nearest neighbor*, *Maximum likelihood* e *Support Vector Machine*.

5.4.2 Acurácias do Usuário e do Produtor

Ao analisarmos a acurácia do usuário que é calculada dividindo o número total de pixels corretamente classificados em uma classe pelo número total de pixels classificados nessa classe, encontramos para a classificação *k-nearest neighbor* os melhores valores para a acurácia de usuário para as classes “Vegetação natural”, “Pastagem”, “Uso antrópico” e “Solo Exposto”, obtendo valores inferiores para a classe “Cultivo”, esses valores refere-se aos erros de comissão a partir da probabilidade que um pixel classificado na imagem tem de representar a classe no campo, como apresentados na Tabela 17.

Tabela 17: Comparação da acurácia do Usuário e do Produtor para cada classe entre os algoritmos *Support vector machine k-nearest neighbor* e *Maximum likelihood*.

Classe	<i>Support Vector Machine</i>		<i>K-nearest neighbor</i>		<i>Maximum likelihood</i>	
	Usuário	Produtor	Usuário	Produtor	Usuário	Produtor
Vegetação natural	89,21	93,49	98,16	85,9	74,15	73,74
Pastagem	82,43	96,08	83,78	99,36	97,99	64,3
Cultivo	87,28	59,95	78,73	89,31	13,54	29,09
Uso antrópico	87,41	92,3	93,2	90,96	1,21	2,88
Solo exposto	96,71	61,79	99,8	92,31	69,1	72,46

Para a acurácia do produtor que é calculada dividindo o número total de pixels corretamente classificados em uma classe, pelo número total de pixels desta classe, indicado na referência de campo, encontramos também para o classificador *k-nearest neighbor*, nas classes “Pastagem”, “Cultivo” e “Solo exposto”, obtendo valores inferiores para as classes “Vegetação natural” e “Uso antrópico”, esses valores refere-se aos erros de omissão, sendo

a probabilidade de um pixel de referência ser corretamente classificado. Todos os valores estão sendo comparados conforme apresentado no Gráfico 5.




Gráfico 5: Comparação da acurácia do Usuário e do Produtor para cada classe entre os algoritmos *Support vector machine*, *k-nearest neighbor* e *Maximum likelihood*.

6. CONCLUSÃO

Os limiares de segmentação utilizados neste trabalho possibilitaram a obtenção de valores de índice kappa e exatidão global altos para os dois classificadores, *K-nearest neighbor*, *Support vector machine*, avaliados.

A segmentação aliada ao algoritmo *K-nearest neighbor* foi a análise que obteve melhores valores nos testes estatísticos, índice kappa e índice de exatidão global e, foi o que possibilitou a melhor discriminação da classe vegetação natural.

Os algoritmos *K-nearest neighbor* e *Support vector machine*, da análise orientada a objetos, apresentaram melhor acurácia quando comparados com o classificador *pixel-a-pixel Maximum likelihood*.

O algoritmo *K-nearest neighbor* se mostrou mais eficiente na discriminação das classes “vegetação natural”, “cultivo”, “solo exposto” e “uso antrópico”, porém quanto a classe “pastagem” foi melhor quantificada com a utilização do algoritmo *Support vector machine*.

Com a utilização da análise orientada a objetos foi possível suprir as limitações espectrais das imagens QUICKBIRD (RGB-321) utilizadas no estudo das áreas de preservação permanente do reservatório da usina hidrelétrica de Funil. A análise orientada a objetos possibilitou mapear e quantificar os diferentes tipos de uso do solo na área de estudo.

7. REFERÊNCIA BIBLIOGRAFICA

ADDISCOTT, T. M. A critical review of the value of buffer zone environments as a pollution control tool. In: HAYCOCK, N. E. et al. (Ed). **Buffer zones: their processes and potential in water protection.** Hertfordshire: Quest Environment, 1997. p. 236-243.

AGUIRRE-GUTIÉRREZ, J.; SEIJMONSBERGEN, A. C.; DUIVENVOORDEN, J. F. Optimizing land cover classification accuracy for change detection, a combined pixel-based and object-based approach in a mountainous area in Mexico. **Applied Geography**, Amsterdam, v. 34, n. 1, p. 29-37, Feb. 2012.

ALENCAR-SILVA, T.; MAILLARD, P. Segmentação de imagens de alta resolução utilizando o programa SMAGIC. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** São José dos Campos: Inpe, 2009. p. 6743-6750. 1 CD-ROM.

ALMEIDA, A. Q.; SANTOS, A. R.; PEZZOPANE, J. E. M. Comparação entre áreas de preservação permanente demarcadas de diferentes escalas topográficas. **Revista Capixaba de Ciência e Tecnologia**, Vitória, v. 28, n. 3, p. 1-8, out. 2007.

ALVES, D. S. et al. Mapeamento do uso da terra em Rondônia utilizando técnicas de segmentação e classificação de imagens TM. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 1996, p. 71-79. Salvador. **Anais...** Salvador: Inpe, 1996.

AMARAL, M. V. F. et al. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estádios de sucessão florestal. **Revista Árvore**, Viçosa, v. 33, n. 3, p. 575-582, jun. 2009.

ARAÚJO, E. H. G. **Análise multi-temporal de cenas do satélite Quickbird usando um novo paradigma de classificação de imagens e inferências espaciais: estudo de caso Belo Horizonte (MG).** 2006. 159 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

AVERY, T. E.; BERLIN, G. L. **Interpretation of aerial photographs.** 4. ed. Minneapolis: Burgess Publishing Company, 1985.

BERNARDI, H. V. F. et al. Classificação digital do uso do solo comparando os métodos “pixel a pixel” e orientada ao objeto em imagem QuickBird. In:

SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Florianópolis: Inpe, 2007. p. 5595-5602.

BLASCHKE, T. et al. Object-oriented image processing in an integrated GIS/Remote sensing environment and perspectives for environmental applications. In: CREMERS, A.; GERVE, K. (Ed.). **Environmental information for planning, politics and the public**: volume 2. Metropolis: Verlag, 2000. p. 555-570.

BLASCHKE, T. Object based image analysis for remote sensing. **Journal of Photogrammetry and Remote Sensing**, New York, v. 65, n. 1, p. 2-16, Feb. 2010.

BOLFE, E. L. et al. Avaliação da classificação digital de povoamentos florestais em imagens de satélite por meio de índices de acurácia. **Revista Árvore**, Viçosa, v. 28, n. 1, p. 85-90, ago. 2004.

BORGES, E. F.; SILVA, A. B. Técnicas de segmentação de imagens e classificação por região: mapeamento da cobertura vegetal e uso do solo, Mucugê-BA. **Mercator**, Fortaleza, v. 8, n. 17, p. 209-220, jun. 2009.

BORGONOVI, M.; CHIARINI, J. V. **Cobertura vegetal do estado de São Paulo. II - Levantamento por fotointerpretação das áreas cobertas com floresta natural e reflorestamento**. *Bragantia*, Campinas, v. 26, n. 6, p. 93-102, jan. 1967.

BRASIL. Lei n. 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa; altera as Leis n^{os} 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis n^{os} 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a Medida Provisória n^o 2.166-67, de 24 de agosto de 2001; e dá outras providências. **Diário Oficial da União**, DF, 28 maio 2012.

BRASIL. Lei n.4.771, de 15 de setembro de 1965. Institui o Novo Código Florestal. **Diário Oficial da União**, DF, 16 set. 1965.

CÂMARA, G. et al. SPRING: integrating remotesensing and GIS byobject-oriented data modelling. **Computer & Graphics**, New York, v. 20, n. 3, p. 395-403, Oct. 1996.

CAMPOS, A. R. et al. Classificação orientada a objeto para mapeamento do uso e cobertura do solo do município de Rio Acima, MG: por crescimento de regiões e por extração de objetos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: Inpe, 2013. p. 8035-8042.

- CARVALHO, L. M. T. de. **Sistemas de informações geográficas e sensoriamento remoto dos recursos florestais**. Lavras: Editora da UFLA, 2004.
- CARVALHO, M. V. A. **Classificação da cobertura e uso do solo com imagens Worldview-2 utilizando mineração de dados e análise baseada em objetos**. 2011. 201 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011.
- CAVALCANTI, G. G.; LOCKABY, B. G. Effects of sediment deposition on aboveground net primary productivity, vegetation composition, and structure in riparian forests. **Wetlands**, Dordrecht, v. 26, n. 2, p. 400-409, Sept. 2006.
- CELESTINO, V. S.; SALDANHA, D. L.; ROCHA, R. S. Avaliação da qualidade de produtos gerados a partir de imagem Quickbird por meio do PEC – Brasileiro. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Florianópolis: Inpe, 2007. p. 507-514.
- CINTRA, D. P. **Classificação de estágios sucessionais florestais por meio de imagens de alta resolução (Ikonos) no Parque Estadual da Pedra Branca, RJ**. 2007. 87 p. Dissertação (Mestrado em Ciências Ambientais e Florestais) - Universidade Federal Rural do Rio de Janeiro, Seropédica, 2007.
- COLLINS, A. L. et al. A preliminary investigation of the efficacy of riparian fencing schemes for reducing contributions from eroding channel banks to the siltation of salmonid spawning gravels across the south west UK. **Journal of Environmental Management**, London, v. 91, n. 4, p. 1341-1349, Jan. 2010.
- COMPANHIA ENERGÉTICA DE MINAS GERAIS. Centro Tecnológico de Minas Gerais. **Guia ilustrado de peixes da bacia do rio Grande**. Belo Horizonte: CEMIG, 2000.
- CORRELL, D. L. Buffer zones and water quality protection: General principles. In: HAYCOCK, N. E. et al. (Ed.). **Buffer zones: their processes and potential in water protection**. Edgewater: Smithsonian Environmental Research Center, 2001. p. 7-20.
- CORTE, A. P. D.; DLUGOSZ, F. L.; CENTENO, J. A. S. Testes de limiares para a segmentação de imagens SPOT-5 visando a detecção de plantios florestais. **Revista Acadêmica de Ciências Agrárias e Ambiental**, Curitiba, v. 6, n. 2, p. 249-257, jun. 2008.

COSTA, T. A. et al. Conflitos de uso da terra na microbacia do São Bartolomeu – Viçosa, MG. **Floresta e Ambiente**, Seropédica, v. 20, n. 3, p. 281-295, jul./set. 2013.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/Unicamp, 1999.

DEFINIENS **imaging. ecognition**: userguide. [S.l.: s.n.], 2007. Disponível em: <<http://www.definiens-imaging.com/down/ecognition>>. Acesso em: 10 març0 2014.

DENT, D.; YOUNG, A. **Soil survey and land evaluation**. London: Allen & Unwin, 1981.

DIETZOLD, S. S.; WENDEL, N. L. **Água sem florestas?** Recife: Editora da UFRPE, 2004.

DIGITALGLOBE. **QuickBird data sheet 2014**. [S.l.: s.n.], 2014. Disponível em: <http://www.digitalglobe.com/sites/default/files/Basic%20Imagery%20Datasheet_0.pdf>. Acesso em: 01 out. 2014.

DUTRA, L. V. et al. **Análise automática de imagens multiespectrais**. São José dos Campos: Inpe, 1981.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Centro Nacional de Pesquisa de Solo. **Sistema brasileiro de classificação de solos**. Rio de Janeiro: Embrapa Solos, 2012.

ESPINDOLA, G. M. **Emprego da estatística espacial na avaliação da segmentação de imagens de sensoriamento remoto**. 2005. 30 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.

FEITOSA, R. Q. et al. Impacto de técnicas baseadas em conhecimento na análise de imagens de média resolução para mapeamento do desflorestamento na Amazônia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. **Anais...** São José dos Campos: Inpe, 2005. p. 4065-4072.

FERNANDES, R. F.; NUNES, G. M.; SILVA, T. S. F. Classificação orientada a objetos aplicada na caracterização da cobertura da terra no Araguaia. **Pesquisa Agropecuária Brasileira**, Brasília, v. 47, n. 9, p. 1251-1260, set. 2012.

FERREIRA, E.; DANTAS, A. A. A.; MORAIS, A. R. de. Exatidão na classificação de fragmentos de matas em imagem do satélite Cbers-CCD, no

município de Lavras, MG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** São José dos Campos: Inpe, 2007. p. 887-894.

FERREIRA, V. M. **Voçorocas no município de Nazareno, MG:** origem, uso da terra e atributos do solo. 2005. 81 p. Dissertação (Mestrado em Solos e Nutrição de Plantas) – Universidade Federal de Lavras, Lavras, 2005.

FRANKLIN, J.; WOODCOCK, C. E.; WARBINGTON, R. Multi-attribute vegetation maps of forest services lands in california supporting resource management decisions. **Photogrammetric Engineering & Remote Sensing**, Falls Church, v. 66, n. 10, p. 1209-1217, Nov. 2003.

GAO, Y. et al. Object-based image analysis for mapping land-cover in a forest area. In: INTERNATIONAL SYMPOSIUM, 5., 2007, The Netherlands. **Proceedings...** The Netherlands: UNAM, 2007. p. 13-15.

GONÇALVES, L.; FONSECA, A. M.; CAETANO, M. Exploração de imagens de alta resolução do satélite Ikonos. In: ENCONTRO DE UTILIZADORES DE INFORMAÇÃO GEOGRÁFICA, 6., 2001, Lisboa. **Anais...** Lisboa: ESIG, 2001. p. 1-22.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais.** São Paulo: Edgard Blücher, 2000.

HU, H.; KIM, N. K. Drinking-water pollution and human health. In: CHIVIAN, E. et al. (Ed.). **Critical condition:** human health and the environment. 2. ed. Cambridge: MIT Press, 1994. p. 31-45.

JACOBSEN, K. Geometric potential of Ikonos- and Quickbird-images. **Photogrammetric Weeks**, Washington, v. 18, n. 3, p. 101-110, June 2003.

JENSEN, J. **Introductory digital image processing:** a remote sensing perspective. New Jersey, Prentice-Hall. 1996.

KAGEYAMA, P. Y. et al. **Restauração da mata ciliar:** manual para recuperação de áreas ciliares e microbacias. Brasília: Secretaria de Meio Ambiente e Desenvolvimento Sustentável, 2002.

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

LEITOLD, V.; POLIZEL, S. P.; MOREIRA, M. A. Mapeamento do uso e cobertura da terra a partir da segmentação e classificação orientada a objetos em imagens do TM/Landsat-5: caso de estudo de parte do município de

Brasil Novo – PA. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** Foz do Iguaçu: Inpe, 2013.

LIBÂNIO, P. A.; CHERNICHARO, C. C. A. L.; NASCIMENTO, N. O. A dimensão da qualidade de água: avaliação da relação entre indicadores sociais, de disponibilidade hídrica, de saneamento e de saúde pública. **Engenharia Sanitária e Ambiental**, Rio de Janeiro, v. 10, n. 3, p. 219-228, abr. 2005.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote sensing and image interpretation**. 5. ed. New York: John Wiley & Sons, 2004.

LILLESAND, T. M.; KIEFER, R.W. **Remote sensing and image interpretation**. New York: John Wiley & Sons, 1987.

LIMA, W. P. Função hidrológica da mata ciliar. In: SIMPÓSIO SOBRE MATA CILIAR, 1998, Campinas. **Anais...** Campinas: Fundação Cargil, 1998. p. 25-42.

LOPES, L. H. M. Uso e cobertura do solo no município de Tailândia-PA utilizando o TM/Landsat e técnica de classificação não-supervisionada. **Engvista**, Manaus, v. 10, n. 2, p. 126-132, dez. 2008.

MARTINELLI, M. Cartografia ambiental: uma cartografia diferente. **Revista do Departamento de Geografia**, São Paulo, v. 7, n. 14, p. 39-46, fev. 1994.

MARUJO, R. F. et al. Classificação orientada a objetos aplicada á cultivos cafeeiros em Três Pontas – MG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2013, Foz do Iguaçu. **Anais...** São José dos Campos: Inpe, 2013. p. 1338-1345.

MEDEIROS, N. G. **Segmentação morfológica aplicada à cartografia**. 2003 123p. Dissertação (Mestrado em Ciências Cartográficas) – Universidade Estadual Paulista, Presidente Prudente, 2003.

MINAS GERAIS. Lei n. 20.922, de 16 de outubro de 2013. Dispõe sobre as políticas florestal e de proteção à biodiversidade no Estado. **Diário do Executivo**, Belo Horizonte, MG, 17 nov. 2013.

MOREIRA, M. A. et al. Geotecnologias para mapear lavouras de café nos estados de Minas Gerais e São Paulo. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 6, p. 1123-1135, dez. 2010.

MOREIRA, S. J. M.; GUIMARÃES, A. G.; DINIZ, A. D. Estudos dos impactos ambientais causados pelo uso e ocupação do solo no bairro

Belvedere III. In: SIMPÓSIO BRASILEIRO DE GEOGRAFIA FÍSICA APLICADA, 10., 2003, Rio de Janeiro. **Anais...** Rio de Janeiro: Editora da UFRJ, 2003. p. 823-830.

MOUNTRAKIS, G.; JUNGHOIM, C. O. Support vector machines in remote sensing: a review. **Journal of Photogrammetry and Remote Sensing**, New York, v. 2011, n. 66, p. 247-259, Dec. 2010.

MYBURGH, G.; NIEKERK, A. V. Effect of feature dimensionality on object-based land cover classification: a comparison of three classifiers. **South African Journal of Geomatics**, Mombray, v. 2, n. 1, p. 13-27, Feb. 2013.

NEWELL, J. E.; OLOFSSON, P. **eCognition tutorial: classifying a QuickBird image**. Boston: Dept of Geography and Environment, University, 2008. Disponível em: <<ftp://crsa.bu.edu/geog-faculty/olofsson/Bostonpan/Tutorial.pdf>>. Acesso em: 15 jun. 2014.

NOMA, A.; KORTING, T. S.; FONSECA, L. M. G. Integração de dados orbitais de sensoriamento remoto para estimar áreas da floresta Ombrófila densa do Estado do Paraná. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: Inpe, 2013. p. 2250-2257.

NOVO, E. M. L. M.; HANSON, J. D.; CURRAN, P. L. The effect of sediment type on the relationship between reflectance and suspended sediment concentration. **International Journal of Remote Sensing**, New York, v. 107, n. 7, p. 1283-1289, July 1989.

OLIVEIRA, J. H. M.; CHAVES, J. M. Utilização de sensores ópticos de média e alta resolução (LANDSAT 7 ETM+ e QUICKBIRD) na caracterização geomorfológica no Raso da Catarina-BA. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Florianópolis: Inpe, 2007. p. 4097-4102.

PACUERA. **Plano de conservação e uso do entorno do reservatório artificial da Usina Hidrelétrica do Funil – PACUERA FUNIL**. Lavras: Consórcio AHE Funil, 2011. Disponível em: <<http://www.ahefunil.com.br/home/downloads>>. Acesso em: 11 nov. 2013.

PEREIRA, L. O. et al. Análise comparativa dos métodos de classificação SVM e Maxver-ICM polarimétrico em imagem de radar ALOS PALSAR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos Campos: Inpe, 2011. p. 8223-8230.

PETRIE, G. **Optical imagery from airborne & spaceborne platforms, comparisons of resolution, coverage & geometry for a given ground pixel size**. The Netherlands: Glasgow, 2002. Disponível em: <http://web2.ges.gla.ac.uk/~gpetrie/28_35_dossier2.pdf>. Acesso em: 16 jan. 2015.

PORTES, R. C. et al., Determinação da fragilidade ambiental da bacia hidrográfica do Ribeirão São Bartolomeu, Viçosa – Minas Gerais, Brasil, por meio de geoprocessamento e análise multi-critério. In: ENCONTRO DE GEÓGRAFOS DA AMÉRICA LATINA, 1., 2009, Montevideo. **Anais...** Montevideo: Inpe, 2009. p. 40-42.

RICHARDS, J. A. Thematic mapping from multitemporal image data using the principal components transformation. **Remote Sensing of Environment**, Amsterdam, v. 16, n. 1, p. 35-46, Jan. 1988.

ROCHA, C. H. B. **Geoprocessamento: tecnologia transdisciplinar**. Juiz de Fora: Editora do Autor, 2000.

ROERDINK, J. B. T.; MEIJSTER, A. The watershed transform: definitions, algorithms and parallelization strategies. **Fundamenta Informatica**, Wageningen, v. 41, n. 1, p. 187-228, Jan. 2001.

ROVANI, F. F. M.; CASSOL, R. Áreas de preservação permanente e conflitos ambientais no município de Barão de Cotegipe (RS): Uma análise com Auxílio das geotecnologias. **Boletim Goiano de Geografia**, Goiânia, v. 32, n. 2, p. 51-70, jul./dez. 2012.

ROZA, W. S. S.; RIBEIRO, S. R. A. Integração de dados orbitais de sensoriamento remoto para estimar áreas da floresta Ombrófila densa do Estado do Paraná. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu. **Anais...** São José dos Campos: Inpe, 2013. p. 3464-3471.

SANTOS, W. J. R. dos et al. Influência do declive na exatidão do classificador MAXVER para o mapeamento da cultura do café. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** Natal: Inpe, 2009. p. 4333-4338.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 2. ed. Oxford: Academic Press, 2006.

SERIGATTO, E. M. **Delimitação automática das áreas de preservação permanente e identificação dos conflitos de uso da terra na bacia hidrográfica do Rio Sepotuba-MT**. 2006. 188 p. Tese (Doutorado em Ciências Florestais) – Universidade Federal de Viçosa, Viçosa, 2006.

SOARES, V. P. et al. Mapeamento de áreas de preservação permanentes e identificação dos conflitos legais de uso da terra na bacia hidrográfica do ribeirão São Bartolomeu – MG. **Revista Árvore**, Viçosa, v. 35, n. 3, p. 555-563, maio/jun. 2011.

SOUZA, F. P. Ocupações irregulares em Áreas de Preservação Permanente: um estudo de caso no município de Campos dos Goytacazes, RJ. **Boletim do Observatório Ambiental Alberto Ribeiro Lamego**, Campos dos Goytacazes, v. 4, n. 1, p. 37-56, jan. / jun. 2010.

STEFFEN, C. A. Técnicas radiométricas com o Spectron SE-590. **Simpósio Brasileiro de Sensoriamento Remoto**, Salvador, v. 8, p. 9-14, 1996.

STRECK, E. V. et al. **Solos do Rio Grande do Sul**. Porto Alegre: Emater, 2002.

SUAREZ, A. F.; CANDEIAS, A. L. B. Avaliação de acurácia da classificação de dados de sensoriamento remoto para o Municí. In: SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO, 4., 2012, Recife. **Anais...** Recife: Inpe, 2012. p. 2-10.

THOMAS, N.; HENDRIX, C.; CONGALTON, R. G. A comparison of urban mapping methods using high-resolution digital imagery. **Photogrammetric Engineering & Remote Sensing**, New York, v. 69, n. 9, p. 963-972, Nov. 2003.

VALENTE, R. O. A. **Definição de áreas prioritárias para conservação e preservação florestal por meio da abordagem multicriterial em ambiente SIG**. 2005. 137 p. Tese (Doutorado em Recursos Florestais) – Universidade de São Paulo, São Paulo, 2005.

VALLE JUNIOR, R. F. et al. Diagnóstico das áreas de preservação permanente na bacia Hidrográfica do Rio Tijuco, Ituiutaba - MG, utilizando tecnologia SIG. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 3, p. 495-503, maio/jun. 2010.

VASCONCELOS, C. H.; NOVO, E. M. Mapeamento da cobertura da terra utilizando técnicas de segmentação e classificação por regiões em imagens: fração, obtidas do sensor TM/LANDSAT, na Região do Reservatório de Tucuruí – PA. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10., 2001, Foz do Iguaçu. **Anais...** São José dos Campos: Inpe, 2001. p. 1035-1038. 1 CD ROM.

VINCENT, L.; SOILLE, P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. **IEEE Transactions on Pattern**

Analysis and Machine Intelligence, Paris, v. 13, n. 6, p. 583-598, June 1991.

VOLPE, L. L.; LOMBARDO, M. A. A análise do uso da terra no entorno do trecho oeste do Rodoanel Mario Covas na cidade de São Paulo por meio de técnicas de Sensoriamento Remoto. **Revista do Departamento de Geografia**, São Paulo, v. 21, n. 2, p. 24-44, Jan. 2011.

XU, Y. et al. Coarse to fine K nearest neighbor classifier. **Pattern Recognition Letters**, North-Holland, v. 34, n. 9, p. 980-986, Feb. 2013.

YAN, G. et al. Comparison of pixel-based and object-oriented image classification approaches-a case study in a coal fire area, Wuda, Inner Mongolia, China. **International Journal of Remote Sensing**, Basingstoke, v. 27, n. 18, p. 4039-4055, Mar. 2006.