

Diogo Felcar Saraiva

**Classificação orientada a objeto
para mapeamento da vegetação
sobre canga couraçada**

XIV Curso de Especialização em
Geoprocessamento
2013



UFMG
Instituto de Geociências
Departamento de Cartografia
Av. Antônio Carlos, 6627 – Pampulha
Belo Horizonte

DIOGO FELCAR SARAIVA

**CLASSIFICAÇÃO ORIENTADA A OBJETO PARA MAPEAMENTO DA
VEGETAÇÃO SOBRE A CANGA COURAÇADA**

Monografia apresentada ao Curso de Especialização em Geoprocessamento da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do título de Especialista em Geoprocessamento.

Orientador: Dr. Rodrigo Affonso de Albuquerque Nóbrega

Belo Horizonte - MG

2013

S243c Saraiva, Diogo Felcar.

2013 Classificação orientada a objeto para mapeamento da vegetação sobre a canga couraçada [manuscrito] / Diogo Felcar Saraiva. – 2013. 42 f. : il. (color.)

Monografia (especialização em Geoprocessamento) – Universidade Federal de Minas Gerais, Instituto de Geociências, 2013.

Orientador: Rodrigo Affonso de Albuquerque Nóbrega.

Bibliografia: f. 42.

1. Geologia ambiental. 2. Campo rupestre. 3. Mapeamento de cobertura do solo. I. Nóbrega, Rodrigo Affonso de Albuquerque. II. Universidade Federal de Minas Gerais, Instituto de Geociências. III. Título.

CDU: 504.73



Universidade Federal de Minas Gerais
Instituto de Geociências
Departamento de Cartografia
Curso de Especialização em Geoprocessamento

Monografia defendida e aprovada em 05 de dezembro de 2013 pela
banca examinadora constituída pelos seguintes professores:



Prof. Dr. Rodrigo A. A. Nobrega - IGC/UFMG - Orientador

Prof. Dr. - IGC/UFMG

“A tarefa não é tanto ver aquilo que ninguém viu, mas pensar o que ninguém ainda pensou sobre aquilo que todo mundo vê.”

Arthur Schopenhauer

AGRADECIMENTOS

No decorrer deste ano, muitos foram os cúmplices deste trabalho. Incentivadores, motivadores, parceiros, conselheiros... Meus sinceros agradecimentos.

Agradeço, a Deus primeiramente, pois tudo correu muito bem na minha adaptação a Belo Horizonte, nas minhas viagens após o trabalho à UFMG, pela saúde física e mental.

Aos meus pais que sempre me ensinaram que a educação é um dos melhores caminhos a seguir na vida. Por serem os maiores incentivadores e não medirem esforços para tal, até mesmo passar uma temporada comigo em BH. Aos meus irmãos sempre presentes e incentivadores dos meus desafios. A minha namorada que sempre me apoiou e “compreendeu” as minhas ausências.

Agradeço a equipe do trabalho, ao meu gestor, Kiko, que me apoiou e nunca se opôs as necessidades advindas da pós e, a Lilian que sempre me incentivou e vibrou com os meus avanços.

Aos ensinamentos dos professores ao longo do curso, em especial ao meu orientador Rodrigo, que confiou a mim a utilização de ferramentas de sensoriamento remoto e por acreditar na minha ideia..

Ao Charles que foi um grande orientador e muito acessível em todas as necessidades ao longo do curso, inclusive no último final de semana.

Aos amigos que fiz durante o curso e sempre me ajudaram, em especial ao Jones, Vitor, Silvana, Alice, Josie, Vanessa e Byron.

RESUMO

A vegetação sobre canga couraçada compõe os afloramentos ferruginosos que estão entre os ecossistemas mais ameaçados e menos estudados de Minas Gerais devido a sua distribuição e associação ao minério de ferro. A análise orientada ao objeto, somada a imagem de alta resolução possibilitam utilizar novos parâmetros na identificação de alvos de dimensões distintas incluindo diferentes tipologias. Neste contexto o objetivo deste estudo foi analisar o potencial de classificação orientada ao objeto em imagem de alta resolução na identificação da vegetação que se desenvolve sobre a **Canga canga Couraçadacouraçada**. Os processamentos digitais de imagem, segmentação multirresolução, componentes principais e razões de bandas, foram realizados na análise exploratória do alvo. Os resultados se apresentaram satisfatórios alcançando 83 % de acerto entre a classificação e os pontos coletados em campo.

Palavras-Chave: Canga Couraçada, Análise Orientada a objeto, *Wordview II*, Componentes Principais.

SUMÁRIO

1.	INTRODUÇÃO.....	9
1.1.	Objetivo.....	10
2.	FUNDAMENTAÇÃO TEÓRICA.....	11
2.1.	Contextualização da vegetação sobre a canga couraçada.....	11
2.2.	Satélite <i>WorldView II</i>	13
2.3.	Processamento digital de imagem.....	15
2.3.1.	Análise de componentes principais em Sensoriamento Remoto.....	15
2.3.2.	Razão de bandas.....	16
2.3.3.	Análise de imagem baseada em objetos.....	17
3.	MATERIAIS E MÉTODOS.....	19
3.1.	Caracterização da área de estudo.....	20
3.2.	Aquisição e características da imagem.....	21
3.3.	Definição das classes de cobertura do solo.....	21
3.4.	Coleta de dados no campo.....	25
3.5.	Processamento digital de imagem.....	25
3.5.1.	Segmentação e classificação de primeiro nível.....	26
3.5.2.	Análise de componente principal.....	29
3.5.3.	Segmentação de segundo nível.....	31
4.	RESULTADOS E DISCUSSÕES.....	34
5.	CONCLUSÕES E CONSIDERAÇÕES FINAIS.....	39
	REFERÊNCIAS BIBLIOGRÁFICAS.....	40

	<u>LISTA DE FIGURAS</u>	vii
--	-------------------------------	-----

	<u>ÍNDICE DE TABELAS</u>	viii
--	--------------------------------	------

1.	<u>INTRODUÇÃO</u>	1
1.1.	<u>Objetivo</u>	2
2.	<u>FUNDAMENTAÇÃO TEÓRICA</u>	3
2.1.	<u>Contextualização da vegetação sobre canga couraçada</u>	3
2.2.	<u>Satélite <i>WorldView II</i></u>	5
2.3.	<u>Processamento digital de imagem</u>	7
2.3.1.	<u>Análise de imagem baseada em objetos</u>	7

<u>2.3.2. Análise de componente principal</u>	8
<u>2.3.3. Razão de bandas</u>	9
<u>3. MATERIAIS E MÉTODOS</u>	11
<u>3.1. Caracterização da área de estudo</u>	12
<u>3.2. Aquisição e características da imagem</u>	12
<u>3.3. Definição das classes de cobertura do solo</u>	13
<u>3.4. Coleta de dados no campo</u>	17
<u>3.5. Processamento digital de imagem</u>	17
<u>3.5.1. Segmentação e classificação de primeiro nível</u>	18
<u>3.5.2. Análise de componente principal</u>	20
<u>3.5.3. Segmentação de segundo nível</u>	22
<u>4. RESULTADOS E DISCUSSÕES</u>	26
<u>5. CONCLUSÕES E CONSIDERAÇÕES FINAIS</u>	31
<u>REFERÊNCIAS BIBLIOGRÁFICAS</u>	32

LISTA DE FIGURAS

Figura 1 – Detalhe da área da cobertura sobre a canga couraçada.....	11
Figura 2 – Detalhe da hematita fragmentada.....	12
Figura 3 – Resposta espectral das bandas do satélite.	15
Figura 4 – Fluxograma metodológico	19
Figura 5 – Localização da área de estudo.....	20
Figura 6 – Adensamentos de <i>Acianthera teres</i> , espécie de orquídea típica dos campos ferruginosos e tipicamente rupícola.	22

Figura 7– Trecho de Canga Couraçada onde ocorrem muitos indivíduos de Lychnophora pinaster (arnica).	22
Figura 8– Figura 8: Canga Couraçada com domínio de Vellozia sp. abaixo e ao fundo estrato arbustivo.	23
Figura 9 – Detalhe da área de transição entre a Canga Nodular (encosta) e a Canga Couraçada.....	23
Figura 10 – Ilhas” de Canga Couraçada.	23
Figura 11 – Pontos amostrados em campo.	25
Figura 12 – Process Tree.	26
Figura 13 – Resultado da classificação nível 1.....	28
Figura 14 – Gráfico da análise das componentes principais mostrando os autovalores das bandas Fonte: Envi-Scree Plot.	29
Figura 15 – Resultado da Composição RGB utilizando CP’s.	30
Figura 16 – Process tree.	31
Figura 17 – Resultado final da classificação.	33
Figura 18 – Setas indicando o alvo destacado.	35
Figura 19 – Resultado final do processamento digital de imagem.....	37
Figura 20 – Comparativo entre a classificação e amostras de campo.	38

ÍNDICE DE TABELAS

Tabela 1 – Características das bandas do satélite <i>WorldView II</i>	14
Tabela 2 – Índices consolidados.	17
Tabela 3 – Chave de interpretação sintetizada.	24
Tabela 4 – Parâmetros utilizados na segmentação.	26
Tabela 5 – Limites com descrição de classes.	27
Tabela 6 – Parâmetros utilizados na segmentação	27
Tabela 7 – Correlação entre as 8 bandas do satélite <i>Worldview II</i>	29
Tabela 8 – Parâmetros utilizados na segmentação.	31
Tabela 9 – Características dos parâmetros selecionados.	32

1. INTRODUÇÃO

O método de classificação de imagens que agrupam os pixels em classes baseado na característica espectral de cada pixel é amplamente difundido. Essa abordagem pode não ser a mais eficaz para classificação de imagens de alta resolução em termos de precisão e produção de redundância devido a grande variabilidade de respostas espectrais, sendo assim, para imagens de alta resolução é possível utilizar objetos com características semelhantes.

O método de segmentação e classificação orientada a objeto, através do processo de segmentação, possibilita agregar atributos para realizar a classificação (SOUSA *et al.*, 2010). A unidade de processamento é composta pelos objetos/regiões da imagem que compartilham atributos semelhantes, tais como: nível de cinza, características espectrais, textura, tamanho, forma, compacidade, informação do contexto dos objetos adjacentes etc. (LIU, 2006).

Esta metodologia, associada à imagem de alta resolução espacial e ao desenvolvimento de novas tecnologias e satélites, permite ampliar a identificação de novos alvos. Dentre os satélites, o *WorldView II* se destaca por ser de alta resolução espacial e fornecer oito bandas espectrais, subsidiando as análises e a identificação de propriedades do ambiente.

Com as ferramentas existentes, satélites e metodologias, tornou-se possível a distinção de novos objetos, assim como a identificação de diferentes tipologias florestais. A canga couraçada compõe o bioma cerrado e, se apresenta no ambiente em áreas que podem ser inferiores a 1 ha. Esta tipologia distribui-se no ambiente em áreas restritas e de difícil acesso, recobrem importantes depósitos de minério de ferro e estão entre os ecossistemas mais ameaçados e menos estudados de Minas Gerais (JACOBI e CARMO, 2008).

Neste contexto, o trabalho visa aplicar a classificação orientada ao objeto de imagem de alta resolução no intuito de ampliar o conhecimento sobre a vegetação que se desenvolve nos afloramentos ferruginosos conhecido como canga couraçada, utilizando a imagem *Worldview II* e o programa *eCognition*.

1.1. **Objetivo**

O objetivo geral deste estudo é analisar o potencial de classificação orientada ao objeto em imagem de alta resolução para identificar a vegetação que se desenvolve sobre a canga couraçada.

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os conceitos que subsidiaram o estudo proposto, o alvo de interesse, a imagem de satélite *Worldview II* e as técnicas de processamento digital de imagem (análise de imagem baseada em objetos, componentes principais e razão entre bandas).

2.1. Contextualização da vegetação sobre a canga couraçada

O Quadrilátero Ferrífero (QF) é considerado uma das regiões de maior diversidade florística da América do Sul (GIULIETTI *et al.*, 1997), marcada pela presença de diversas espécies endêmicas e/ou ameaçadas de extinção. Trata-se de um ambiente único onde ocorrem campos rupestres ferruginosos, citado entre as 112 áreas consideradas mais importantes para a conservação da biodiversidade no estado de Minas Gerais (DRUMMOND *et al.*, 2005).

A vegetação associada a afloramentos hematíticos tem sido classificada como “campo rupestre sobre canga” (VIANA e LOMBARDI, 2007) ou “Campos Ferruginosos” (VINCENT, 2004). A canga não é um ambiente uniforme e alguns autores descrevem diferentes tipologias. Rizzini (1979) denomina canga couraçada a vegetação que cresce sobre os afloramentos hematíticos (Figura 1) e a vegetação savânica adjacente, com o solo rico em fragmentos de hematita, é denominada canga nodular (Figura 2). Observa-se que canga nodular é originada a partir da fragmentação da canga couraçada e se concentram nas encostas das cristas e dos platôs.



Figura 1 – Detalhe da área da cobertura sobre a canga couraçada.



Figura 2 – Detalhe da hematita fragmentada.

As cangas couraçadas ocorrem em locais onde o substrato forma uma espessa e sólida couraça ou lajeado, sobre a qual a vegetação se desenvolve de maneira esparsa com espécies predominantemente herbáceas epilíticas e rupícolas crescendo sobre a rocha ou algumas arbustivas e arbóreas crescendo em fendas. Algumas vezes, o substrato é de tal forma ausente que a vegetação inexistente e a cobertura do solo se reduz a líquens e musgos.

Uma vez que o tipo de formação rochosa encontrada nos campos ferruginosos ocorre apenas no Quadrilátero Ferrífero e em algumas disjunções na região Norte do Brasil (serra dos Carajás) e em Corumbá- MS, e juntas essas áreas correspondem a 8% das reservas mundiais de minério de ferro de alta qualidade, este pode ser considerado um dos ecossistemas atualmente mais ameaçado pela interferência antrópica (DRUMMOND *et al.*, 2005). Muitas espécies dos campos rupestres estão listadas como ameaçadas de extinção, em razão da sua raridade intrínseca, estreita distribuição geográfica e forte pressão antrópica sobre seu habitat (MENEZES e GIULIETTI, 2000).

Carmo (2010) determinou as áreas para todas as cangas do Quadrilátero Ferrífero e a estimativa de perda utilizando imagens geradas entre 2002 e 2009 e a ferramenta “Régua”, ambas disponibilizadas no programa *Google Earth Pro*. A área total das cangas atinge atualmente cerca de 11.170 ha, distribuídas entre 225 afloramentos com áreas médias entre 49,7 e 171,3 ha (CARMO, 2010). De acordo com Carmo (2010) em pouco mais de 40 anos já foram irreversivelmente perdidos aproximadamente 7.340 ha de cangas, cerca de 40% da área de referência, e foram extintos 100 afloramentos ferruginosos. Entre as áreas de canga remanescentes, 107 perderam até 4% da área original, 59 perderam entre 5% e 30%, 34 perderam entre 31% e 60% e 25 perderam

entre 61% e 95% da área de referência. Aproximadamente 53% das áreas remanescentes foram constituídas de cangas que perderam entre 5% até 30% do habitat (CARMO, 2010).

2.2. Satélite *WorldView II*

O *WorldView II* é um satélite comercial de alta resolução espacial e pioneiro no fornecimento de oito bandas espectrais no intervalo do visível até próximo ao infravermelho (Tabela 1) em alta resolução. Cada sensor é estritamente centrado num determinado intervalo do espectro electromagnético que é sensível a uma característica específica no solo ou a uma propriedade do ambiente (DIGITALGLOBE, 2010).

De acordo com a DigitalGlobe (2011) o satélite transporta o instrumento de imagem contendo uma alta resolução da banda pancromática com resposta reduzida do azul e infravermelho e oito bandas espectrais de menor resolução espacial. As bandas multiespectrais geram precisão de cor e bandas para várias aplicações exclusivas. Além das bandas conhecidas como a *red*, *green* e *blue* e *near-infrared (NIR)* similares porém distintas do satélite *Quickbird*, adicionou-se mais quatro bandas, a *coastal blue*, *red edge*, *yellow* e a *NIR 2* com um maior comprimento de onda.

Tabela 1 – Características das bandas do satélite *WorldView II*.

Bandas dos Sensores	Faixas Espectrais (nm)	Resolução Espacial (m)	Resolução Radiométrica bits/pixel	Papel das Bandas
Coastal Blue	400 - 450	2	11	<ul style="list-style-type: none"> • Faixa exclusiva para WorldView-02; • Absorvida pela clorofila em plantas saudias e ajuda na realização de análise vegetativa; • Menor absorção pela água e, portanto, penetra mais profundamente na água limpa do que qualquer outra banda; • Substancialmente influenciado pela dispersão atmosférica e possui o potencial de melhorar as técnicas de correção atmosférica.
Blue	450 - 510	2	11	<ul style="list-style-type: none"> • Faixa azul é projetado para a penetração do corpo de água; • Útil para solo da discriminação da vegetação e mapeamento do tipo de floresta; • Menos afetado pela dispersão atmosférica e absorção em comparação com a Banda Coastal Blue.
Green	510 - 580	2	11	<ul style="list-style-type: none"> • Capaz de se concentrar mais precisamente no pico de reflectância da vegetação saudável; • Ideal para calcular o vigor da planta; • Muito útil para discriminar entre tipos de material de plantas quando utilizado em conjunto com a banda Yellow; • Também é útil para aplicações batimétricas.
Yellow	585 - 625	2	11	<ul style="list-style-type: none"> • Faixa exclusiva para WorldView-02; • Importante para aplicações de vegetação e turbidez; • Detecta o "amarelado" da vegetação em particular, tanto em terra como na água; • Útil para a identificação de característica da vegetação; • Muito importante para característica de classificação.
Red	630 - 690	2	11	<ul style="list-style-type: none"> • Melhor foco na absorção da luz vermelha pela clorofila em vegetais saudáveis; • Útil para a análise da vegetação e para diferenciar os tipos de plantas; • Útil para a identificação característica das culturas; • Muito útil na classificação de solos nus, estradas, e nas características geológicas.
Red Edge	705 - 745	2	11	<ul style="list-style-type: none"> • Faixa exclusiva para WorldView-02; • Centrado estrategicamente no início da porção de alta reflectividade da resposta da vegetação; • Auxilia na análise da vegetação e estado vegetativo através do estado da clorofila; • Muito valioso para medir a saúde das plantas e ajudar na classificação da vegetação.
NIR1	770 - 895	2	11	<ul style="list-style-type: none"> • Muito eficaz para a estimativa do teor de umidade e biomassa vegetal; • Efetivamente separa corpos de água de vegetação, identifica os tipos de vegetação e também discriminar entre tipos de solo; • A banda NIR também é útil para identificar o vigor da vegetação, estudos de biomassa e para a discriminação da umidade do solo.
NIR2	860 - 1040	2	11	<ul style="list-style-type: none"> • Sobrepõe a banda NIR1, mas é menos afetados pela influência atmosférica; • Permite uma análise mais ampla e vegetação estudos de biomassa; • Também é útil para delinear a influência do vapor de água e para a diferenciação de materiais.
Pancromática	450 - 800	0,5	11	–

Fonte: DigitalGlobe, 2010.

Conforme gráfico apresentado na Figura 3 é possível identificar a resposta da radiância espectral relativa nas oito bandas apresentadas pelo o satélite *Worldview II*, que devido

entrada de novas bandas, há a possibilidade de distinção e melhora na identificação dos objetos da imagem.




Figura 3 – Resposta espectral das bandas do satélite.
Fonte: DigitalGlobe (2011).

2.3. Processamento digital de imagem

A função básica do processamento digital de imagens de sensoriamento remoto é a de gerar mecanismos para subsidiar o tratamento das imagens e também a identificação e a extração da informação contidas nas imagens. Nesse sentido, sistemas dedicados de computação são utilizados para atividades interativas de análise e manipulação das imagens brutas. Assim é possível a produção de outras imagens, estas já contendo informações específicas, extraídas e realçadas.

2.3.1. Análise de componentes principais em Sensoriamento Remoto

Análise de componentes principais é um procedimento matemático que proporciona reduzir a dimensionalidade dos dados multivariados através da mudança (translação e rotação dos eixos do sistema cartesiano no espaço de atributos). Os novos eixos do sistema são posicionados de forma a maximizar a variância dos dados, fazendo com que nova representação possibilite a redução da correlação entre os dados multivariados.

A técnica tem sido amplamente aplicada em diversos campos, incluindo Sensoriamento remoto. Conforme Almeida e Souza (2011) normalmente há uma alta correlação entre as bandas individuais de uma imagem multiespectral, tanto visual como numericamente. Ela advém do efeito de sombras resultantes da topografia, da sobreposição das janelas espectrais entre bandas adjacentes e do próprio comportamento espectral dos objetos. Devido à redundância encontrada nas bandas a análise espectral poderá ser prejudicada.

A técnica de geração de componentes principais (CP) permite um realce que reduz ou remove esta redundância espectral, ou seja, gera um novo conjunto de imagens cujas bandas individuais apresentam informações não disponíveis em outras bandas. As novas imagens perdem significativamente qualidade para análises visuais em comparação com as originais, porém representam um conjunto de dados com menor ambiguidade para as análises numéricas.

As informações gerais das bandas decrescem da primeira CP gerada até a última, a qual apresentará basicamente o ruído existente nos dados iniciais. A primeira componente principal contém a informação de brilho associada às sombras de topografia e às grandes variações da refletância espectral geral das bandas. Ela possui a maior parte da variância total dos dados, concentrando a informação, antes diluída, em várias dimensões. A segunda e as subsequentes componentes principais apresentam gradativamente menos contraste entre os alvos e são desprovidas de informação topográfica, devido à ausência de sombreamento. Esta transformação é derivada da matriz de covariância entre as bandas e gera um novo conjunto de imagens onde cada valor de "*pixel*" é uma combinação linear dos valores originais (ALMEIDA e SOUZA 2011).

2.3.2. Razão de bandas

Conforme Meneses e Almeida (2012), ao utilizar imagens de sensores multiespectrais, em diversas situações há o interesse de discriminar na cena refletância de alvos de interesse, como um tipo de litologia, vegetação, recursos hídricos etc. Neste contexto, para destacar as propriedades do alvo determinado, a razão de bandas é a operação aritmética usada para este fim, transformando-se em uma das mais úteis e abrangentes técnicas de transformação de imagem. Ela se baseia em parâmetros dos aspectos físicos do sensor e no comportamento da refletância dos alvos.

A divisão trabalha no realce das assinaturas espectrais dos alvos e, para isso, é necessário que o usuário selecione corretamente as bandas do sensor. Esta seleção das bandas é decidida com base no conhecimento que o intérprete tem acerca do padrão de refletância do alvo de interesse. Daí decorre ser uma técnica controlada pelo intérprete, aplicada para o mapeamento litológico, de solos ou de vegetação (MENENES, ALMEIDA, 2012).

De acordo com Meneses e Almeida (2012) algumas razões de bandas para determinadas classes são muito difundidas, tais como índice de vegetação "Ratio Vegetation Index – RVI", *Normalize Difference Vegetation Index* – NDVI e *Soil Adjusted Vegetation Index* – SAVI e, para os corpos hídricos é possível utilizar a diferença normalizada da água – *Normalize Difference Water Index* – NDWI (Tabela 2).

Tabela 2 – Índices consolidados.

ÍNDICES	RAZÕES
RVI	NIR/RED
NDVI	$(NIR-RED)/(NIR+RED)$
SAVI	$(NIR-RED)/(NIR+RED)*(1+L^1)$
NDWI	$(G-NIR)/(G+RED)$

Fonte: Meneses e Almeida (2012).

¹:Constante da fórmula de SAVI.

2.3.3. **Análise de imagem baseada em objetos**_[r1]

OBIA surgiu de pesquisas na Alemanha e Áustria com a finalidade de proporcionar uma solução ao novo paradigma que o Sensoriamento remoto viria a enfrentar: a alta variância das imagens de alta resolução espacial. Muitas das técnicas de classificação tradicionais baseadas em pixel têm como base parâmetros estatísticos que são extraídos das amostras para classificação. Segundo Nóbrega (2007), diferente das imagens de média resolução espacial como LANDSAT por exemplo, as imagens de alta resolução possibilitam captar uma quantidade maior de detalhes, a qual é diretamente proporcional ao aumento da variância dos dados nela representados. A utilização de objetos (segmentos) extraídos das imagens através de pixels homogêneos permite que a análise possa extrapolar os dados oriundos dos pixels, e introduzir novas formas de análise baseadas na geometria, no contexto e na hierarquia dos objetos.

Neste trabalho, ao invés da análise se basear nos pixels, ela se realiza baseada nos objetos (*Object Based Image Analysis* – OBIA), a referência são os objetos criados através dos algoritmos de segmentação (BENZ *et al.*, 2004; BAATZ e SCHÄPE, 2000). A segmentação divide uma imagem em regiões ou objetos formados por pixels (GONZALEZ; WOODS, 2008). Blaschke (2010) define segmentos como regiões geradas por um ou mais critérios de homogeneidade em uma ou mais dimensões do

espaço de atributos. Dessa forma, os objetos gerados pelos algoritmos de segmentação são utilizados na classificação.

Portanto, para se trabalhar com a OBIA é preciso gerar objetos pela segmentação (BAATZ e SCHÄPE, 2000). A criação dos objetos permite a determinação de atributos baseados nos próprios objetos, como atributos estatísticos, texturais, de forma, topológicos e semânticos, podendo utilizar diferentes níveis de segmentação (FERNANDES, 2013). Assim, um conjunto inicial de *pixels* ou de objetos adjacentes é agrupado em novos objetos baseado no crescimento de regiões (BAATZ; SCHÄPE, 2000).

No presente trabalho, foi utilizado o algoritmo de segmentação multirresolução implementado no *software eCognition 8.7* (BAATZ; SCHÄPE, 2000). É possível trabalhar com diversos níveis de segmentação e utilizar restrições nos processos. Portanto, os objetos de uma imagem podem ser representados em diferentes escalas (BENZ *et al.*, 2004). O primeiro nível de segmentação é criado a partir do agrupamento dos próprios *pixels* de uma imagem ou de um conjunto de imagens. Os demais níveis podem ser gerados a partir de outros objetos. Por exemplo, é possível segmentar objetos de uma determinada classe em outro nível de segmentação para a criação de uma subclasse de acordo com a rede hierárquica.

Configura-se o algoritmo de acordo com a imagem e os pesos de cada uma para serem utilizadas na segmentação, através de três parâmetros: escala, que é uma medida de heterogeneidade referente ao tamanho dos objetos, quanto maior seu valor, maior serão os objetos criados; forma (*shape*), que define o peso da forma na segmentação, assim, um valor baixo implica no maior peso no uso da cor, que é baseada nas características espectrais (ou valores de *pixels*) da imagem; e compactidade (*compactness*), que compõe o critério de forma junto com a suavidade, e define o peso do critério de compactidade dos objetos, por exemplo, um valor baixo cria objetos mais alongados e com bordas suaves, enquanto um valor alto implica em objetos mais compactos e menores, para os dois últimos parâmetros aplica-se peso de 0 a 1, podendo assim evidenciar mais entre a forma e cor ou entre a compactidade e suavidade (BAATZ e SCHÄPE, 2000).

3. MATERIAIS E MÉTODOS

Os passos metodológicos realizados estão resumidos no fluxograma da Figura 4, na sequência as etapas estão descritas e contextualizadas.

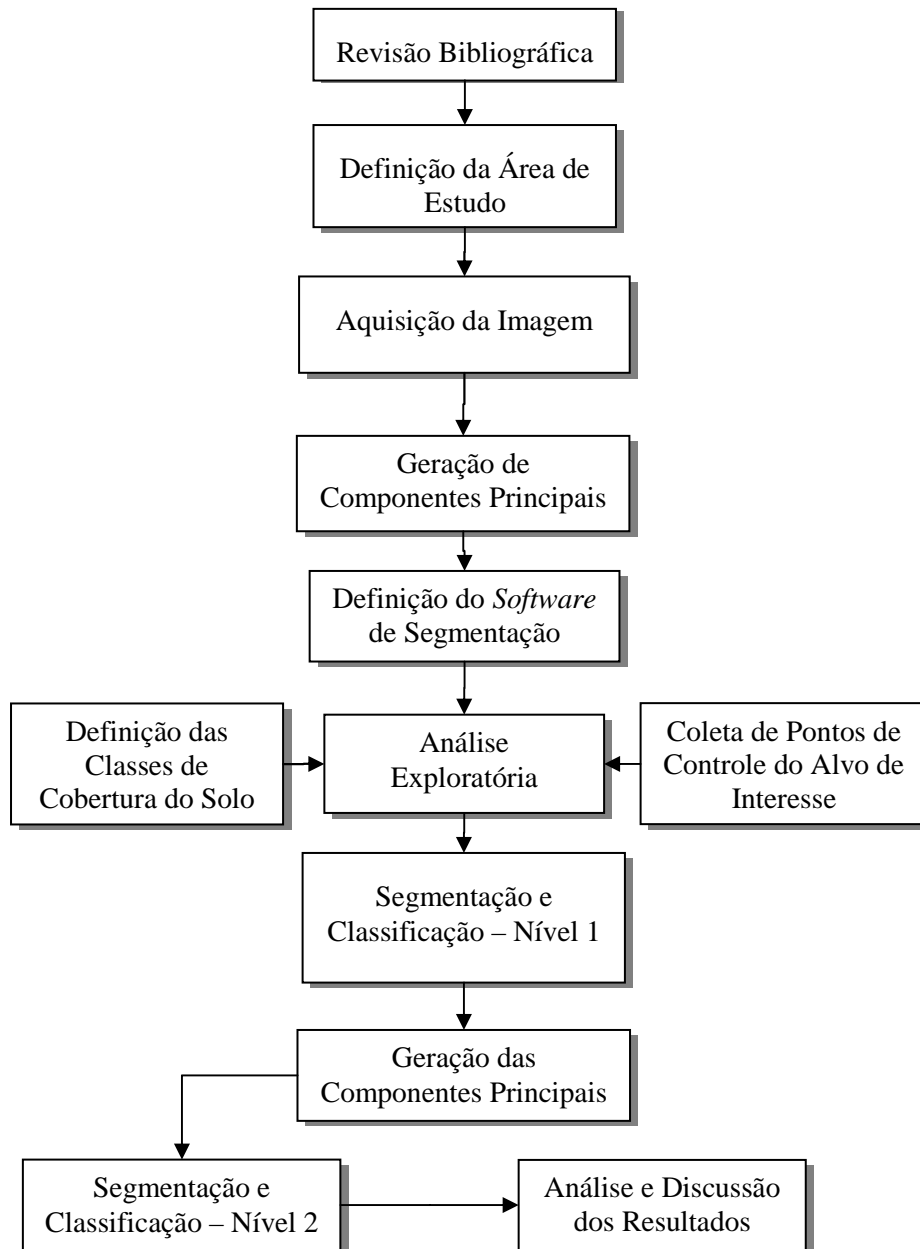


Figura 4 – Fluxograma metodológico.

3.1. Caracterização da área de estudo

A área de estudo está localizada na região limítrofe aos municípios de Nova Lima, Brumadinho, Moeda e Itabirito, com área aproximada de 23 km² limitada pela Serra da Moeda (Figura 5). A área selecionada apresenta os campos ferruginosos e está delimitada à leste pela coordenada E=608.916,48E, à oeste pela coordenada E=605.875,69, ao sul pela coordenada N=7.758.931,53 e ao norte pela coordenada N=7.768.565,23, coordenadas estas projetadas em UTM, Zona 23S no Sistema Referencial SAD 69.

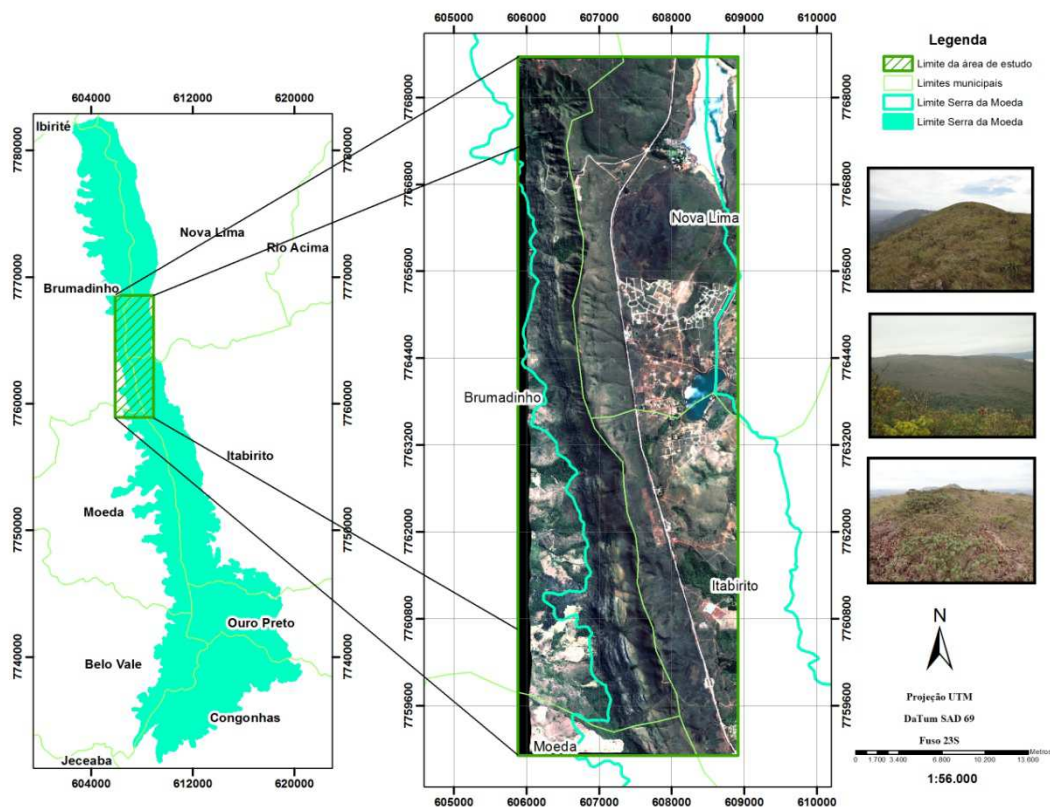


Figura 5 – Localização da área de estudo.

A Serra da Moeda caracteriza-se pela elevada heterogeneidade vegetal, onde é possível encontrar floresta estacional semidecidual, matas ripárias, florestas montanas, campo cerrado, cerrado sensu strictu, campos rupestres quartzíticos, graníticos e ferruginosos. O clima da região é do tipo CWb com verões quentes e chuvosos e invernos secos (NIMER & BRANDÃO, 1989).

3.2. Aquisição e características da imagem

Neste trabalho é utilizada imagem de alta resolução espacial do satélite *Worldview II* (DIGITALGLOBE, 2010).

Característica da imagem:

- Banda pancromática com resolução espacial de cinquenta centímetros somada a composição das bandas multiespectrais *coastal blue* (400-450 nm), *blue* (450-510 nm), *green* (510-580 nm), *yellow* (585-625 nm), *red* (630-690 nm), *red edge* (705-745 nm), *NIR1* (770-895 nm), *NIR2* (860-1040 nm), com resolução espacial de dois metros;
- Resolução radiométrica de 11 bits/banda;
- 0% Percentual de nuvens na área de interesse;
- Escala visual de trabalho até 1:1.500;
- Georreferenciada;
- Projeção cartográfica UTM – SAD 69, Fuso 23 S;
- Ajuste de borda;
- Ajuste de contraste;
- Realce e equalização;
- Ortorectificação;^[13]
- Imagem com bandas não fusionadas.

A aquisição da imagem teve como premissa evitar a época de estiagem devido à incidência de incêndios florestais, porém para a área de interesse e descrição da imagem, havia apenas uma cena em acervo datada de setembro de 2010.

3.3. Definição das classes de cobertura do solo

As classes de cobertura do solo foram definidas com base na análise visual das imagens *WorldView II* e visitas a campo para reconhecimento da área de estudo e identificação dos alvos presentes na cena.

As classes definidas foram: vegetação densa, corpos d'água/água, solo exposto e baixa cobertura vegetal, áreas pavimentadas e construções, área queimada, herbácea e a vegetação sobre a Canga Couraçada (Tabela 3).

Como o objetivo do estudo foi à identificação da vegetação sobre Canga Couraçada, a delimitação das demais classes permitiu focar nas áreas que realmente fosse possível a sua delimitação. Devido à diversidade inerente a esta tipologia, além das informações apresentadas na Tabela 3, nas Figura 7, 8, 9 e Figura 10 estão os alvos objeto deste trabalho.



Figura 6 – Adensamentos de *Acianthera teres*, espécie de orquídea típica dos campos ferruginosos e tipicamente rupícola.



Figura 7– Trecho de Canga Couraçada onde ocorrem muitos indivíduos de *Lychnophora pinaster* (arnica).



Figura 8– Figura 8: Canga Couraçada com domínio de *Vellozia sp.* abaixo e ao fundo estrato arbustivo.











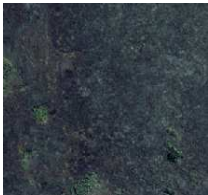



Figura 9 – Detalhe da área de transição entre a Canga Nodular (encosta) e a Canga Couraçada.



Figura 10 – “Ilhas” de Canga Couraçada.

Tabela 3 – Chave de interpretação sintetizada.

Classe	Cor	Exemplo imagem WorldViewII	Descrição
Vegetação densa			Caracterizada por um grande número de árvore e arbustos agrupados.
Vegetação densa incendiada			Área com densidade de vegetação afetada pela queimada.
Corpos d'água			Caracterizada por lagos, lagoas e reservatórios artificiais identificados na imagem.
Área antropizada			Caracterizada por áreas pavimentadas, construções e solo exposto.
Área queimada			Caracterizada por áreas afetadas por incêndios florestais.
Vegetação sobre Canga Couraçada			Caracterizada vegetação herbácea e arbustiva sobre a canga couraçada.
Vegetação não potencial			Caracterizada por vegetação herbácea arbustiva não associada à canga couraçada.

3.4. Coleta de dados no campo

Os pontos coletados no levantamento de campo permitiram a caracterização dos alvos de interesse norteando a posterior segmentação através do programa *eCognition*.

Foram coletadas as coordenadas de 262 pontos, utilizando um receptor GPS Garmin 60CSX, na Figura 11 é apresentada a distribuição espacial desses pontos.

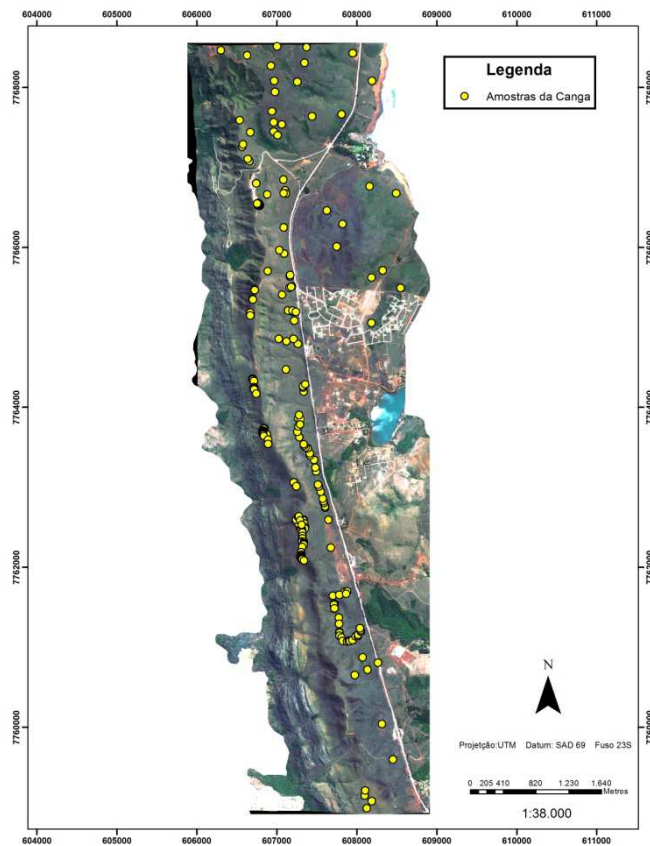


Figura 11 – Pontos amostrados em campo.

3.5. Processamento digital de imagem

Os programas utilizados neste trabalho foram: *ArcGIS*, *Envi* e *eCognition* que permitiram a análise exploratória do alvo. Esta análise norteou o processamento em três etapas: segmentação e classificação de primeiro nível, para excluir as áreas que o alvo não ocorria; geração de componentes principais, para realçar os atributos do produto gerado pela etapa anterior; e segmentação e classificação de segundo nível, para identificação do alvo utilizando as componentes principais.

3.5.1. Segmentação e classificação de primeiro nível

Nesta etapa optou-se por identificar as classes definidas e conhecidas que não interferiam no objeto de estudo, ou seja, as classes descritas na Tabela 3, como: área queimada, área antropizada, corpos hídricos, vegetação densa, vegetação densa afetada por incêndio e vegetação não potencial. As demais áreas consideradas como potenciais não foram classificadas nesta fase.

O algoritmo utilizado foi o *multiresolution segmentation*, o qual funde *pixels* existentes nos objetos de imagem através de uma análise de homogeneidade espectral. O procedimento identifica objetos de imagem simples de um pixel de tamanho e mescla com os seus vizinhos baseado em critérios de homogeneidade relativa. Este critério de homogeneidade é uma combinação de critérios espectrais e forma (BENZ, *et al.*, 2004).

Criou-se uma árvore de processo, (*Process Tree*, ilustrada na Figura 12), e a segmentação foi realizada através das combinações de escala, forma e cor (Tabela 4). De acordo com a análise da imagem e, levantamento realizado em campo, foi utilizado uma escala maior, pois neste momento buscou-se a separação dos locais que não havia a ocorrência de canga ou foram afetados pelos incêndios.

Tabela 4 – Parâmetros utilizados na segmentação.

<i>Shape</i>	<i>Compactness</i>	Escala	Peso *RGB
0.5	0.0	1000	2*R, 2*NIR1, 2*B

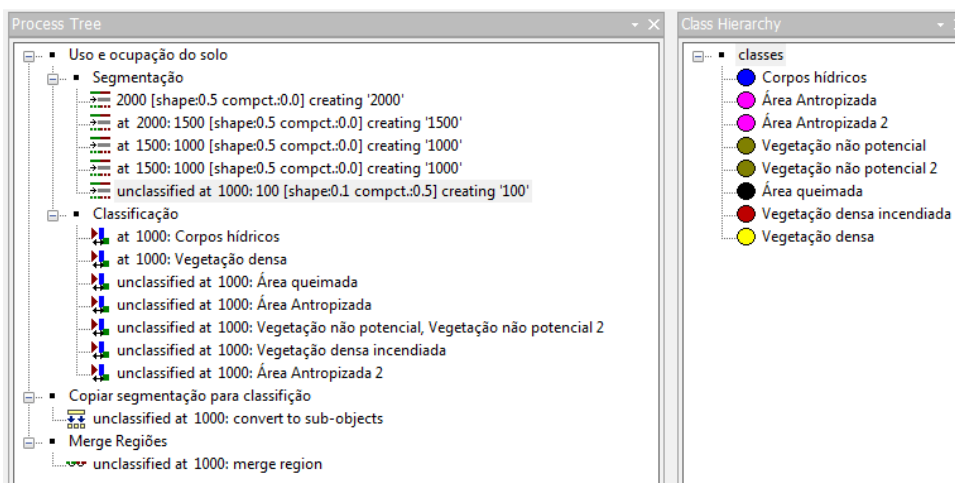


Figura 12 – *Process Tree*.

As classes criadas, conforme Figura 12, no item *Class Hierachy*, receberam limites - *thresholds* (Tabela 5) de acordo com as variáveis *NDVI*, *NDWI* e *Brightness*. Os

thresholds são condições limites que determinam se um objeto de imagem corresponde a uma condição ou não. É possível atribuir objetos de imagem para uma classe com base em apenas uma condição; no entanto, a vantagem do uso de descrições de classes reside na combinação de várias condições. O conceito de condições de limite também está disponível para a classificação baseada no processo, neste caso, a condição de limite é parte do objeto de imagem e pode ser adicionado para a maioria dos algoritmos (TRIMBLE, 2011).

Tabela 5 – Limites com descrição de classes.

Variáveis	Corpos Hídricos		Área antropizada		Área antropizada 2		Vegetação não potencial		Vegetação não potencial 2		Área queimada		Vegetação densa incendiada		Vegetação densa	
	Contained		Contained		Contained		Contained		Contained		Contained		Contained		Contained	
	<i>and</i>	<i>or</i>	<i>and</i>	<i>or</i>	<i>and</i>	<i>or</i>	<i>and</i>	<i>or</i>	<i>and</i>	<i>or</i>	<i>and</i>	<i>or</i>	<i>and</i>	<i>or</i>	<i>and</i>	<i>or</i>
	x		x		x			x	x		x		x		x	
NDVI			< 0.17		< 0.08				<0.197; >0.1759		< 0.21		≤0.2896; ≥0.2894			
NDWI	> 0														> 0.3	
Brightness							<445; >600				< 450					

Conforme ilustrado sequência de processos da *Process Tree* (Figura 12), as classes definidas na *Class Hierarchy*, com os seus devidos limites, foram classificadas na sequência, utilizando os objetos da imagem sem classificação. Após classificar todos os objetos não potenciais, realizou-se uma nova segmentação com novos parâmetros da classe *unclassified* (

Tabela 6). Esta etapa foi realizada com o intuito de classificar os fragmentos da vegetação densa que devido à escala anteriormente utilizada não foram segmentados.

Tabela 6 – Parâmetros utilizados na segmentação

Shape	Compactness	Escala	Peso *RGB
0.1	0.5	100	2*R, 2*NIR1, 2*B

Esta nova segmentação foi utilizada para classificação realizada na escala 1000. Após classificação destes novos objetos (vegetação densa), os objetos (segmentos)

pertencentes à mesma classe foram agrupados através da ferramenta *merge region*, resultando em uma imagem mais generalizada, apresentada na Figura 13.




Figura 13 – Resultado da classificação nível 1.

3.5.2. Análise de componente principal

Ao analisar a imagem original do *Worldview II*, utilizando o programa Envi, foi possível identificar a alta correlação entre as suas bandas (Tabela 7).

Tabela 7 – Correlação entre as 8 bandas do satélite *Worldview II*.

Correlation	Band 1	Band 2	Band 3	Band 4	Band 5	Band 6	Band 7	Band 8
Band 1	1.000.000	0.966196	0.927904	0.883901	0.809646	0.620825	0.458071	0.422616
Band 2	0.966196	1.000.000	0.967658	0.921650	0.864637	0.639089	0.450481	0.423553
Band 3	0.927904	0.967658	1.000.000	0.966290	0.919951	0.765229	0.580690	0.558026
Band 4	0.883901	0.921650	0.966290	1.000.000	0.964509	0.759208	0.536616	0.521267
Band 5	0.809646	0.864637	0.919951	0.964509	1.000.000	0.732860	0.520713	0.505480
Band 6	0.620825	0.639089	0.765229	0.759208	0.732860	1.000.000	0.939191	0.933611
Band 7	0.458071	0.450481	0.580690	0.536616	0.520713	0.939191	1.000.000	0.986889
Band 8	0.422616	0.423553	0.558026	0.521267	0.505480	0.933611	0.986889	1.000.000

Fonte: Procedimento realizado no programa Envi - *Statistics Results*.

Segundo Almeida e Souza (2011), a primeira componente principal contém a maior variância total de dados. Diante disso, ao analisar os autovalores da imagem é possível verificar a concentração de dados nas primeiras componentes principais (Figura 14).

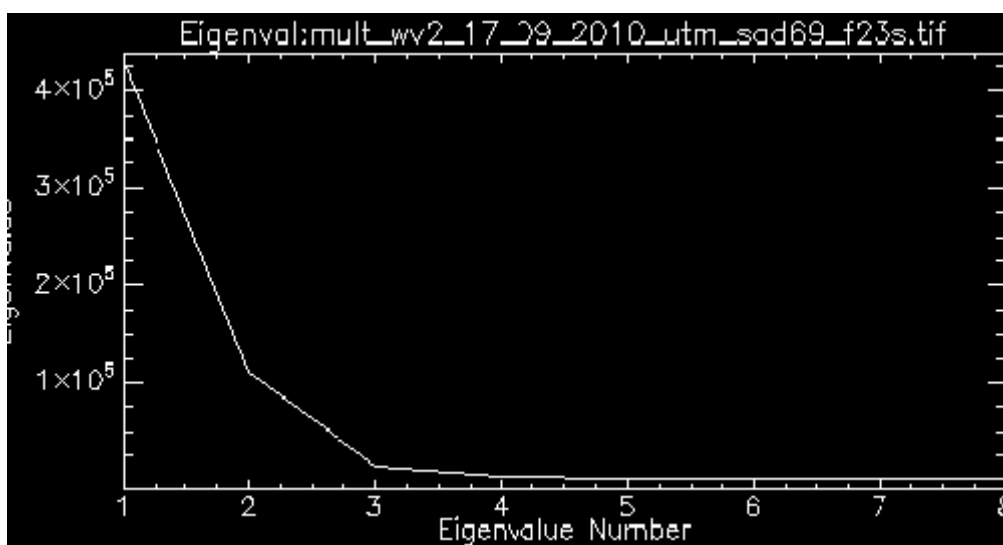


Figura 14 – Gráfico da análise das componentes principais mostrando os autovalores das bandas
Fonte: Envi-*Scree Plot*.

Baseado no gráfico acima, é possível constatar que as três primeiras CP são as mais representativas, correspondendo a 76%, 20 % e 3 % da variância total dos dados, respectivamente. Portanto, o usuário pode escolher as componentes que melhor caracterizam as informações a serem extraídas, reduzindo-se o número de bandas utilizadas no processamento (FONSECA, 2000). Sendo assim, as classes definidas

como não potenciais, geradas pela segmentação e classificação nível 1 foram utilizadas para recortar a imagem no programa ArcGIS, gerando apenas as componentes principais da área potencial através do programa Envi (Figura 15).




Figura 15 – Resultado da Composição RGB utilizando CP.

3.5.3. Segmentação de segundo nível

As componentes principais, geradas na etapa anterior, foram segmentadas utilizando o algoritmo *multiresolution segmentation*, para o qual uma nova árvore de processo foi criada, *Process Tree* (Figura 16). Nesta fase o foco foi identificar o alvo de interesse, por isso apenas duas classes foram criadas, a vegetação associada à canga couraçada e a “não canga”. Para tanto, novos parâmetros foram inseridos buscando uma maior segmentação da imagem (Tabela 8).

Tabela 8 – Parâmetros utilizados na segmentação.

Shape	Compactness	Escala	Peso *RGB
0.3	0.7	30	1*CP1, 1*CP2, 1*CP3

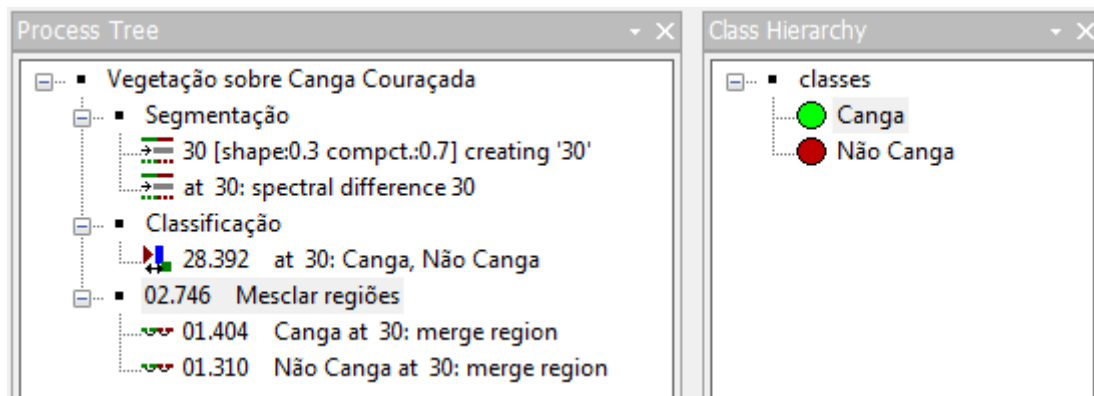


Figura 16 – *Process tree*.

Após a segmentação, foi realizado um refinamento da segmentação através do algoritmo *Spectral Difference Segmentation*, utilizando o resultado anterior. A *Spectral Difference Segmentation* permite mesclar objetos vizinhos da imagem se a diferença entre as camadas média de intensidade é inferior ao valor máximo determinado pela diferença espectral, nesta fase o valor utilizado no parâmetro escala foi 30. Este algoritmo é projetado para refinar os resultados de segmentação existentes, através da fusão objetos de imagem espectralmente semelhantes produzidos por segmentações anteriores e, portanto, é uma segmentação de baixo para cima (TRIMBLE, 2011).

Com o resultado da segmentação foram coletadas amostras das duas classes, e os parâmetros para melhor diferenciá-las foram avaliados pelo método *Feature Space Optimization function*, que matematicamente calcula a melhor combinação de recursos no espaço de atributos para classificar objetos gerados pela segmentação (TRIMBLE,

2011). Os parâmetros selecionados e aplicados às classes referentes as três CP's foram: *maximum difference*, *contrast to neighbor pixels layer 1*, *ratio layer 1, 2 e 3*; os quais são descritos na

Tabela 9.

Tabela 9 – Características dos parâmetros selecionados.

Função	Descrição
<i>Max. difference</i>	Retorna o valor máximo dos valores de recurso de um objeto de imagem e seus vizinhos de uma classe selecionada.
<i>Ratio</i>	Calcula a proporção entre o valor de característica de um objeto imagem e o valor característica média de seus vizinhos de uma classe selecionada. Note-se que para a média dos valores característicos são ponderados com a área da correspondente objetos de imagem.
<i>Contrast to neighbor pixels</i>	Os valores dos pixels dos objetos criados comparados aos seus vizinhos

Fonte: *Trimble* (2011).

Para classificação supervisionada utilizou-se o algoritmo de vizinho mais próximo, contadas as distâncias euclidianas no espaço de atributos (*Nearest Neighbor*) – NN, que se baseia nas amostras coletadas pelo usuário (Figura 17). O algoritmo busca através das amostras do objeto da imagem no espaço de característica de cada objeto, assim o objeto mais próximo da amostra será atribuído a uma determinada classe (TRIMBLE, 2011). O resultado das classes foi agrupado através da ferramenta *merge region*.

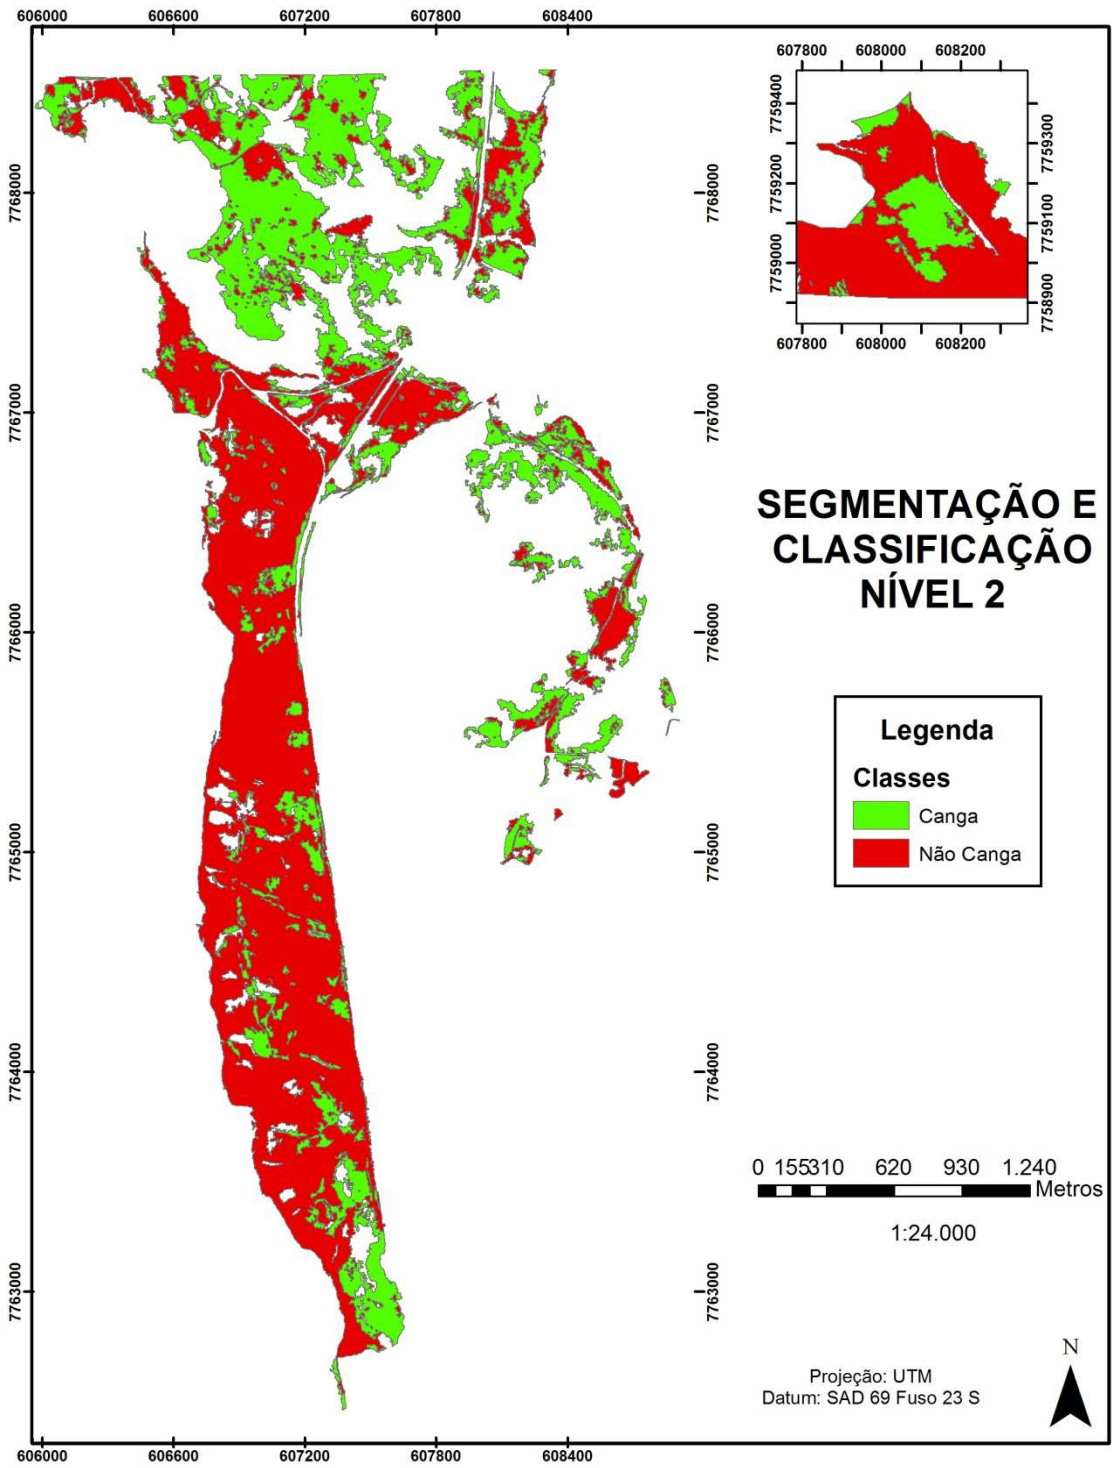


Figura 17 – Resultado final da classificação.

4. RESULTADOS E DISCUSSÕES

A estratégia definida para a análise exploratória do alvo se mostrou essencial para a obtenção do resultado final. A utilização de limites para a classificação de primeiro nível subsidiou a identificação das classes não potenciais. Conforme Tabela 5, os limites da variável *NDVI* puderam ser aplicados em diferentes classes, pois além de diferenciar a vegetação, o resultado adverso evidencia a sua ausência, facilitando a identificação de áreas antropizadas. O parâmetro brilho evidenciou a grande área afetada pelos incêndios a qual influenciou consideravelmente no resultado final do trabalho, pois muitas áreas identificadas no campo foram retiradas da classe de interesse. O parâmetro *NDWI* se mostrou muito eficiente na identificação da classe de corpos hídricos.

Com as classes não potenciais excluídas, gerou-se as componentes principais da área entendida como potencial. Na Figura 18 pode-se observar o destaque da área de interesse.




Figura 18 – Setas indicando o alvo destacado.

Apesar das exclusões realizadas na etapa anterior, as tonalidades geradas na composição RGB CP1, CP2 e CP3 possibilitaram identificar algumas classes associadas a ela (Figura 18), como: vegetação mais densa com a coloração roxa, vegetação herbácea com a tonalidades laranja, áreas incendiadas com a tonalidades verde e as áreas de canga variando da coloração ciano ao cinza azulado com alguns arbustos. Esta variação

corrobora com os recentes estudos que evidenciam elevada diversidade florística sobre a canga. Jacobi e Carmo (2008) realizaram levantamentos em quatro afloramentos com área disjuntas totais < 300 ha e, das 458 espécies de plantas vasculares apenas 5% deste total foram encontradas em todos os afloramentos.

A última etapa do processamento digital foi subsidiada pelo produto gerado pelas CP. A nova segmentação e classificação nível 2, através das amostras coletadas, objetivou diferenciar as respostas espectrais dos objetos em duas classes, a canga e a não canga. O algoritmo segmentador *Spectral Difference Segmentation*, agrupou os objetos vizinhos otimizando a coleta de amostras para posterior classificação. Nesta fase os parâmetros analisados pelo método *Optimization function* definiu a *Max. difference, contrast to neighbor pixels layer 1, ratio layer 1, 2 e 3* como os melhores para tal e, através do algoritmo *Nearest Neighbor – NN* a classificação foi realizada.

Ao agrupar todas as camadas geradas nas etapas do trabalho e compará-las com as amostras coletadas em campo foi possível avaliar o resultado da classificação e quantificar a porcentagem de acerto entre o resultado do processamento e pontos coletados (Figura 19). Foi possível identificar que grande parte das amostras está contida nas áreas classificadas como queimada.

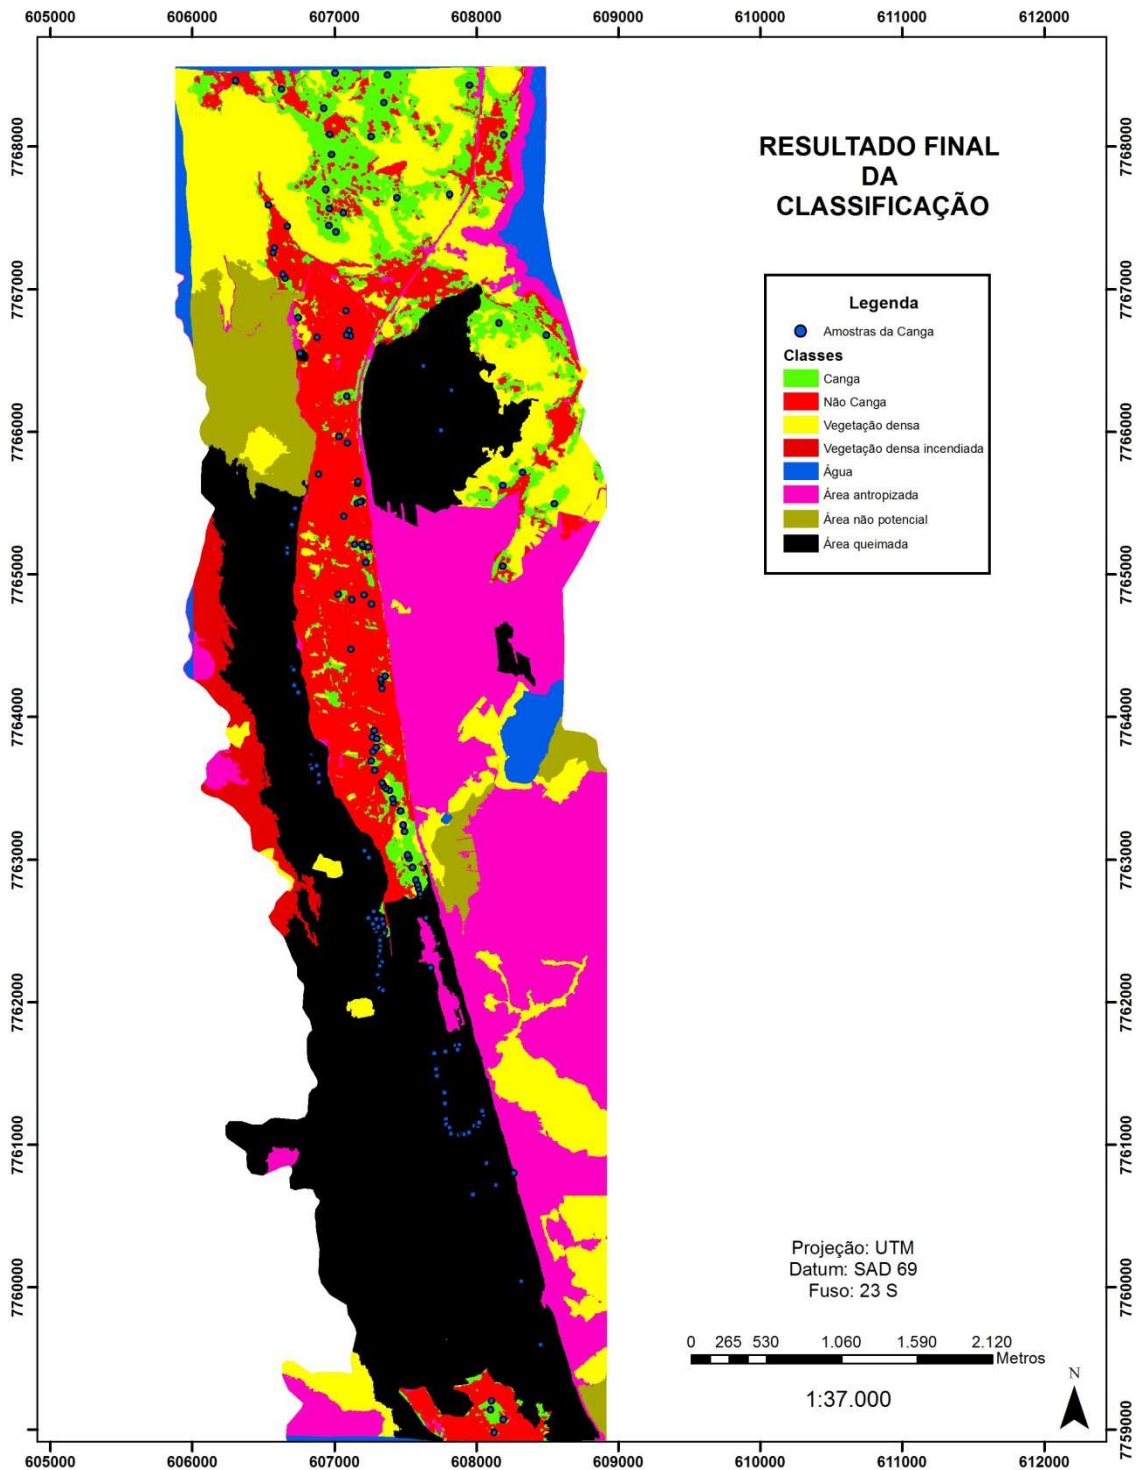


Figura 19 – Resultado final do processamento digital de imagem

Naturalmente, a vegetação arbustiva que em determinadas regiões se apresentam mais densa e estão intrinsecamente associadas à canga couraçada foram classificadas em outra classe. Isto ocorreu devido ao refinamento utilizado para a delimitação de objetos de menor área.

Excluindo as amostras influenciadas pelas queimadas chegou-se a um resultado de 83 % de acerto entre as amostras de campo e a classificação (Figura 20). Muitos polígonos da classe canga, além dos amostrados em campo, foram delimitados, uma porcentagem provavelmente foram confundidos devido à alta diversidade desta tipologia e as demais foram áreas não visitadas em campo.




Figura 20 – Comparativo entre a classificação e amostras de campo.

De acordo com o objetivo proposto pelo presente trabalho, os processamentos se mostraram eficazes no mapeamento do alvo, principalmente devido o resultado gerado pelas componentes principais que possibilitou evidenciar as áreas de canga.

A ausência de PDI aplicados a esta tipologia é um universo a ser explorado. Novas análises utilizando diferentes algoritmos e parâmetros, principalmente relacionado à textura, poderão gerar resultados expressivos. Neste estudo, as segmentações em diferentes níveis excluindo as áreas de não interesse e a geração de componentes principais, se mostraram satisfatórios no mapeamento da vegetação sobre canga couraçada.

5. CONCLUSÕES E CONSIDERAÇÕES FINAIS

O processamento digital de imagem se mostrou eficaz na identificação da vegetação sobre canga couraçada. A análise orientada ao objeto utilizando a imagem *WorldView II* proporcionou uma ampla análise exploratória nas etapas definidas para o processamento. A exclusão das classes identificadas como não potenciais favoreceu a extração de informação do alvo de interesse através das componentes principais. Apesar da interferência dos incêndios afetando as áreas de canga e da grande diversidade apresentada pelo alvo, chegou-se no resultado de 83 % de acerto entre a classificação e as amostras coletadas em campo. A acurácia da classificação foi medida de forma absoluta, comparando-se os resultados das áreas de canga encontrados na classificação diretamente com a localização das áreas de canga mapeadas em campo. Portanto, independente da ausência de estudos aplicados a esta tipologia a qual possibilita um universo a ser explorado no PDI, a metodologia de classificação orientada ao objeto para identificação da vegetação que se desenvolve sobre a canga couraçada se mostrou um promissor caminho para ampliar o conhecimento desta tipologia ainda pouco conhecida.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, W. S.; SOUZA, N. M. Avaliação das informações espectrais dos dados WorldView 2/Digital Globe para classificação temática de uso e cobertura do solo. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15. (SBSR), 2011, Curitiba. **Anais...** São José dos Campos: INPE, 2011.

BAATZ, M.; BENZ, U.; DEGHANI, S.; HEYNEN, M.; HÖLTJE, A.; HOFMANN, P.; LINGENFELDER, I.; MIMLER, M.; SOHLBACH, M.; WEBER, M.; WILLHAUCK, G. **e-Cognition Professional User Guide 4**. München, Germany: Definiens Imaging GmbH, 486 p., 2004.

BAATZ, M.; SCHÄPE, A. **Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation**. In: STROBL, J., BLASCHKE, T. (eds.). *Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT Symposium Salzburg 2000*. Karlsruhe: Herbert Wichmann Verlag, 2000. p. 12–23.

BENZ, U. C.; HOFMANN, P.; WIKKHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. **multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information**. *Photogrammetry & Remote Sensing*, v. 58, p. 239- 258, 2004.

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

CARMO, F. F. 2010. **Importância Ambiental e Estado de Conservação dos Ecossistemas de Cangas no Quadrilátero Ferrífero e Proposta de Áreas-Alvo para a Investigação e Proteção da Biodiversidade em Minas Gerais**. Dissertação apresentada ao Programa de Pós-graduação em Ecologia, Conservação e Manejo da Vida Silvestre (ECMVS) da Universidade Federal de Minas Gerais - UFMG. Belo Horizonte –MG.

DIGITALGLOBE. **DigitalGlobe Spectral Response**. 2011. Disponível em: <http://www.digitalglobe.com/sites/default/files/DigitalGlobe_Spectral_Response_0.pdf>. Acesso em: 15 set. 2013.

DIGITALGLOBE. **The Benefits of the Eight Spectral Bands of WorldView-2**. 2010. Disponível em: <http://www.digitalglobe.com/sites/default/files/DG-8SPECTRAL-WP_0.pdf>. Acesso em: 15 set. 2013.

DRUMMOND, G.M., C.S. MARTINS, A.B.M. MACHADO, F.A. SEBAIO & Y. ANTONINI (org.). 2005. Biodiversidade em Minas Gerais: Um Atlas para sua Conservação. 2ª. ed. Belo Horizonte: Fundação Biodiversitas. 222 p., 2005.

FERNANDES, P. J. F. **Dados SRTM e derivados no mapeamento geomorfológico regional**. 2013. 93 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.

FONSECA, L. M. G. **Processamento Digital de Imagens. Notas de aulas da disciplina de PDI nos programas de pós-graduação dos cursos de Sensoriamento Remoto e Computação Aplicada**. INPE, 2000. 6: p. 72-90.

GIULIETTI, A. M. et al. **Espinhaço Range region**. In: Davis, S. D.; Heywood, V. H.; MacBryde, O. H.; Villa-Lobos, J. e Hamilton, A. C. (eds.). Centers of plant diversity: a guide e strategy for their conservation. Cambridge. Pp. 397-404, 1997.

GONZALEZ, R. C. AND WOODS, R. E. 2008. **Digital Image Processing, 3rd ed.**, Prentice Hall, Upper Saddle River, NJ.

JACOBI, C. M.; CARMO, F. F. 2008. **Diversidade dos campos rupestres ferruginosos no Quadrilátero Ferrífero, MG**. Megadiversidade, no prelo.

LIU, Y.; LI, M.; MAO, L.; XU, F.; HUANG, S. 2006. **Review of Remotely Sensed Imagery Classification Patterns Based on Object-oriented Image Analysis**. Chinese Geographical Science. n. 16, p. 282-288.

LUZ, J. **Imagens ALOS para o mapeamento da vegetação arbórea e outros usos do solo em área de Floresta Ombrófila Mista**. 121f. Dissertação (Mestrado em Engenharia Florestal) – Setor de Ciências Agrárias, Universidade Federal do Paraná, 2009.

MENESES, P. R.; ALMEIDA, T. (org.) **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: CNPq, 2012. 266 p.

MENEZES, N.Z. E GIULIETTI, A.M. 2000. **Campos rupestres**. Pp. 65-73. In: M.P. Mendonça e L.V. Lins (eds.). Lista vermelha das espécies ameaçadas de extinção da flora de Minas Gerais. Minas Gerais, Belo Horizonte, Fundação Biodiversitas e Fundação Zoo-Botânica de Belo Horizonte.

MONTEIRO, A.; LINGNAU, C.; SOUZA JR, C. Classificação orientada a objetos para detecção da exploração seletiva de madeira na Amazônia. **Revista Brasileira de Cartografia**. Rio de Janeiro, v. 3, n. 59, p. 225-234, 2007.

MONTEIRO, A.; LINGNAU, C.; SOUZA JR, C. Classificação orientada a objetos para detecção da exploração seletiva de madeira na Amazônia. **Revista Brasileira de Cartografia**. Rio de Janeiro, v. 3, n. 59, p. 225-234, 2007.

NIMER, E. & BRANDÃO, A. M. P. M. 1989. **Balanço hídrico e clima da região dos Cerrados**. Instituto Brasileiro de Geografia e Estatística (IBGE), Rio de Janeiro, 166p.

NOBREGA, R. A. A. 2007. Detecção da malha viária na periferia urbana de São Paulo utilizando imagens de alta resolução espacial e classificação orientada a objetos. **Tese de Doutorado**, Escola Politécnica da Universidade de São Paulo, São Paulo, 166 p. <http://www.teses.usp.br/teses/disponiveis/3/3138/tde-10082007-171032/>

RIBEIRO, S. R. A.; SANTOS, D. R. dos; CENTENO, J. S. Aplicação da metodologia de dados orientado a objeto na classificação de uma área urbanizada, utilizando uma imagem digital obtida por meio da tecnologia do laser scanner. In: SIMPÓSIO BRASILEIRO DE GEOMÁTICA, 2002. Presidente Prudente. **Anais...** Presidente Prudente, p.144-149, 2002.

RIZZINI, C. T. Tratado de fitogeografia do Brasil. **Aspectos sociológicos e florísticos**. HUCITEC/EDUSP, São Paulo, 374p.; 1979.

SILVA, ANTÔNIO MACHADO E. **Curso Processamento digital de imagens de satélite**. Centro de Eventos da PUCRS - de 07 a 12 de outubro de 2001. Porto Alegre - RS. Disponível em www.cartografia.org.br. Acesso em: 25 nov. 2013.

SINDIEXTRA-FIEMG. 2008. **Patrimônio Natural-Cultural e Zoneamento Ecológico-Econômico da Serra da Moeda: Uma Contribuição para sua Conservação**, 489 p.

SOUSA, A. M. O; MESQUITA, P.; GONÇALVES, A. C. SILVA, J. R. M. 2010. Segmentação e classificação de tipologias florestais a partir de imagens QUICKBIRD. **Ambiência - Revista do Setor de Ciências Agrárias e Ambientais**. Guarapuava, PR, v.6 Ed. Especial, p.57 – 66.

TRIMBLE. **eCognition**. Version 8.7. Software. 2011.

VIANA, P. L.; LOMBARDI, J. A. **Florística e Caracterização dos Campos Rupestres sobre Canga na Serra da Calçada, Minas Gerais, Brasil**. *Rodriguésia*, 58(1): 159-177, 2007.