



Universidade de Brasília
Instituto de Ciências Humanas
Departamento de Geografia
Programa de Pós-Graduação em Geografia

UnB

**Avaliação do Uso da Abordagem Orientada-Objeto com Imagens de Alta
Resolução RapidEye na Classificação das Fitofisionomias do Cerrado**

Juan Carlos Orozco Filho

DISSERTAÇÃO – MESTRADO

Brasília – DF, Julho 2017.



Universidade de Brasília
Instituto de Ciências Humanas
Departamento de Geografia
Programa de Pós-Graduação em Geografia

**Avaliação do Uso da Abordagem Orientada-Objeto com Imagens de Alta
Resolução RapidEye na Classificação das Fitofisionomias do Cerrado**

Juan Carlos Orozco Filho

Orientador: Osmar Abílio de Carvalho Júnior

DISSERTAÇÃO – MESTRADO

Brasília – DF, Julho 2017.



Universidade de Brasília
Instituto de Ciências Humanas
Departamento de Geografia
Programa de Pós-Graduação em Geografia

Avaliação do Uso da Abordagem Orientada-Objeto com Imagens de Alta Resolução RapidEye na Classificação das Fitofisionomias do Cerrado

Juan Carlos Orozco Filho

Banca examinadora constituída por:

Prof. Dr. Osmar Abílio de Carvalho Júnior

Prof. Dra. Potira Meirelles Hermuche

Prof. Dra. Juliana Maria Oliveira Silva

Brasília – DF, Julho 2017.



Universidade de Brasília
Instituto de Ciências Humanas
Departamento de Geografia
Programa de Pós-Graduação em Geografia

Sumário

RESUMO	vi
ABSTRACT	vii
1. INTRODUÇÃO	1
2. ÁREA DE ESTUDO	4
3. MATERIAIS E MÉTODOS.....	7
3.1. Imagens RapidEye.....	8
3.2. Segmentação da Imagem	9
3.3. Classificação usando Árvore de Decisão.....	13
3.4. Definição das Classes de Fitofisionomias do Cerrado	18
3.5. Análise de Acurácia.....	21
4. RESULTADOS.....	25
4.1 Resultado da classificação usando a árvore de decisão J48	25
4.2 Resultado da classificação usando árvore de decisão construída pelo usuário.....	29
5. DISCUSSÃO	34
6. CONCLUSÃO	36
REFERÊNCIAS BIBLIOGRÁFICAS.....	38



Universidade de Brasília
Instituto de Ciências Humanas
Departamento de Geografia
Programa de Pós-Graduação em Geografia

Lista de figuras

Figura 1: Mapa de Localização da Imagem RapidEye 2333907 na Estação Ecológica da Serra Geral do Tocantins.	6
Figura 2: Fluxograma do processamento digital de imagem da imagem Rapideye.	7
Figura 3: Parâmetros da Segmentação na Imagem.....	11
Figura 4: a) composição colorida RGB (5-2-1), b) imagem segmentada.	13
Figura 5: Representação da Estrutura da Árvore de Decisão	14
Figura 6: a) Composição colorida RGB (5-2-1) da imagem RapidEye, b) Seleção de objetos amostrais para treinar a árvore de decisão J48.	17
Figura 7: Fotos das Fitofisionomias do Bioma Cerrado: a) Campo Limpo Úmido/Veredas; b) Mata de Galeria; c) Campo Limpo; d) Cerrado Ralo; e) Cerrado Típico e f) Cerradão.....	21
Figura 8: Imagem Verdade.....	23
Figura 9: Árvore de Decisão usando o J48.....	25
Figura 10: a) Composição colorida RGB (5-2-1) da imagem RapidEye, b) Classificação de área amostral de acordo com a árvore de decisão J48.....	26
Figura 11: Mapa da Classificação Final Produzida pelo Minerador de Dados J48 na Imagem RapidEye da cena 2333907 de 13/06/2011.	28
Figura 12: Árvore de Decisão Obtida por Testes de Parâmetros e Limites	29
Figura 13: a) Composição colorida RGB (5-2-1) da Imagem RapidEye, b) Classificação da área amostral de acordo com a árvore de decisão produzida pelo usuário através de testes de parâmetros e limiares.	31
Figura 14: Mapa da classificação produzida pela árvore de decisão elaborada manualmente na imagem RapidEye da cena 2333907 de 13/06/2011.....	33



Universidade de Brasília
Instituto de Ciências Humanas
Departamento de Geografia

UnB

Programa de Pós-Graduação em Geografia

Lista de tabelas

Tabela 1: Formulação dos índices espectrais, onde NIR é infravermelho próximo, SWIR é infravermelho de ondas curtas, Red é a faixa do vermelho, Blue é a faixa do azul.	15
Tabela 2: Matriz de confusão da classificação usando a árvore de decisão J48.....	27
Tabela 3: Matriz de Confusão da Classificação por Testes de Parâmetros e Limiares.....	32

RESUMO

O bioma Cerrado ocupa uma extensa área do território brasileiro e a sua degradação vem sendo intensificada com a expansão das fronteiras agrícolas na região. O sensoriamento remoto tem servido como uma importante ferramenta para monitorar os danos ambientais e entender a complexidade desse bioma. O objetivo desse trabalho é estabelecer mapear as fitofisionomias do bioma Cerrado na Estação Ecológica Serra Geral do Tocantins, utilizando uma abordagem orientada-objeto em uma imagem de alta resolução espacial do sensor RapidEye. No processamento digital de imagens foi utilizado o programa Interimage, desenvolvido especificamente para a classificação orientada a objetos. A imagem foi segmentada pelo método multi-resolução (*TAA Baatz Segmentator*) e classificada por duas técnicas de árvore de decisão: algoritmo J48 e pela definição do usuário. As fitofisionomias selecionadas na classificação foram: Campo com Solo Exposto, Campo Limpo/Sujo, Cerrado Stricto Sensu (compreende Cerrado Ralo, Cerrado Típico e Cerrado Denso), Floresta (compreende Cerradão e Mata de Galeria/Ciliar), Campo Limpo Úmido/Veredas e Áreas Queimadas. A classificação usando algoritmo J48 teve uma acurácia total de 81% e índice Kappa de 0,704, enquanto a árvore de decisão definida manualmente de 86% e índice Kappa de 0,783. Desta forma, a utilização da abordagem orientada-objeto com a técnica de árvores de decisão apresenta uma ferramenta importante na diferenciação das fitofisionomias do Cerrado.

ABSTRACT

The Cerrado biome occupies an extensive area of the Brazilian territory and its degradation has been intensified with the expansion of the agricultural frontiers. Remote sensing has served as an important tool for monitoring environmental damage and ecological dynamics of the Cerrado biome. The objective of this research is to map the phytophysionomies of the Cerrado biome at the Serra Geral do Tocantins Ecological Station, using an object-oriented classification in a high spatial resolution image of the RapidEye sensor. Digital image processing utilized the Interimage program, specifically developed for object-based classification. We use the multiresolution segmentation (TAA Baatz Segmentator) and two classification techniques for decision tree: J48 algorithm and user definition. The selected phytophysionomies in the classification were: Grassland with Bare Ground (Campo com Solo Exposto), Grassland (Campo Limpo / Sujo), Savanna (Cerrado Stricto Sensu), Forest (Cerradão and Gallery Forest), Wet Grassland (Campo Limpo Úmido / Veredas) and Burned Areas. The classification using J48 algorithm had an overall accuracy of 81% and Kappa index of 0.704, while the manually defined decision tree an overall accuracy of 86% and Kappa index of 0.783. Thus, the use of object-based orientation along with decision trees is an important tool to distinguish Cerrado's phytophysionomies.

1. INTRODUÇÃO

O Cerrado é uma vegetação que possui fortes relações ecológicas e fisionômicas com outras savanas da América Tropical, da África, do Sudeste Asiático e da Austrália (Ribeiro e Walter, 2008) e cobre uma área de mais de 2 milhões de quilômetros quadrados (IBGE, 2004). A Savana é definida como uma vegetação que compreende um estrato gramíneo contínuo, usualmente com árvores e/ou arbustos (Cole, 1986). A colonização do interior do país data de quase três séculos atrás, no entanto, foi apenas com a modernização agrícola na década de 1970 que se iniciou o processo de conversão da vegetação natural do Cerrado em áreas de produção de commodities agropecuárias (Brasil, 2013). Além da expansão agrícola, incêndios frequentes se espalham pela região causando consequências devastadoras, tais como perda da biodiversidade, aumento na emissão dos gases do efeito estufa e problemas de saúde causados pela fumaça (Carvalho Júnior et al., 2015). Os problemas existentes neste bioma colocam o Cerrado em uma lista de vinte e cinco biomas que são classificados como *hotspot*, áreas do mundo sob forte ameaça de perdas ambientais irreparáveis e com elevado endemismo (Myers et al., 2000).

A identificação e o monitoramento da vegetação natural são um dos principais atributos para o manejo e conservação da biodiversidade (Gibbons et al., 2006). Neste propósito, uma importante ferramenta é o processamento digital de imagens de sensoriamento remoto, que permite uma visão sinóptica da paisagem, repetitividade de informações, diminuição de custos e rapidez. Conforme a revisão de Xie et al. (2008), o mapeamento da vegetação por sensoriamento remoto envolve diferentes tipos de imagens, processamentos e técnicas.

Nas últimas décadas, a interpretação de imagens de média resolução espacial como a Landsat Thematic Mapper (TM) e a SPOT foi uma importante ferramenta no mapeamento de alvos terrestres como a vegetação e as áreas urbanas. No entanto, estas imagens provaram ser insuficientes ou inadequadas para aplicações em estudos mais detalhados (Harvey & Hill, 2001). Neste contexto, o sensoriamento remoto de imagens de alta resolução ganha força por ser capaz de

extrair informações mais precisas de alvos menores. Inicialmente, muitos estudos relacionados a regiões urbanas foram elaborados devido a limitações das imagens de média resolução na identificação desses alvos (Carleer & Wolff, 2004). Na medida em que usuários de sensoriamento remoto foram se capacitando e o acesso a imagens de alta resolução se tornou maior, mais trabalhos com observações detalhadas da vegetação foram surgindo. As imagens multiespectrais tiradas tanto de satélites como de aeronaves podem ser obtidas em resoluções espaciais menores que 1 metro (Ehlers et al, 2003).

Desde o surgimento do sensoriamento remoto, foi demonstrado o poder das informações espectrais contidas nos pixels na classificação das imagens. Entretanto, a tradicional abordagem baseada no pixel é pouco eficiente para a classificação de imagens de alta resolução, porque se limita a uma pura categorização descritiva do seu espectro (Rittl et al., 2013). Na superação desse problema, a análise de imagem orientada a objetos (Object-Based Image Analysis - OBIA) foi introduzida com o propósito de ir além da informação espectral e incluir feições do objeto, tais como: forma, textura e contexto/relação (Jobin et al., 2008). Esta abordagem possui fundamentos na segmentação de imagem e nas análises espaciais baseadas em Sistema de Informação Geográfica (SIG) para a extração de feições (Blaschke, 2010). A abordagem OBIA consiste de um novo paradigma para a classificação de imagens (Blaschke et al., 2014), sendo amplamente utilizada nos estudos de vegetação (Addink et al., 2007, Chen et al., 2012; Rapinel et al., 2014; Mora et al., 2010).

Esse método é bastante recomendado em paisagens heterogêneas, como ocorrem nas savanas, onde as densidades diferenciadas de árvores produzem na classificação baseada em pixel um efeito de sal e pimenta (Gibbes et al., 2010, Whiteside et al., 2011). Na identificação das fitofisionomias do Cerrado é preciso descrever a composição espacial e a densidade de indivíduos arbóreos, que repercute nos processos ecológicos e na formação de microhabitats (Gibbes et al., 2010). Whiteside et al., (2011) constatam que a classificação baseada em objeto apresenta uma maior acurácia do que a classificação por pixel em regiões savânicas da Austrália. Gibbes et al.,

(2010) obtiveram bons resultados no mapeamento das savanas africanas a partir de imagens de alta resolução IKONOS, usando o índice de vegetação NDVI e a classificação orientada objeto.

A presente pesquisa possui como objetivo avaliar o emprego da classificação orientada a objeto de imagens de alta resolução RapidEye a fim de garantir uma classificação acurada das fitofisionomias do Cerrado. Esta classificação se baseou na criação de duas árvores de decisão, uma produzida pelo minerador de dados J48 e outra através de testes no programa pelo usuário. As árvores de decisão são estruturas que permitem uma classificação através de um teste lógico que efetua uma divisão dos objetos entre as classes estabelecidas. O minerador de dados produz a árvore de decisão por intermédio da seleção de amostras de objetos de cada classe e da seleção dos melhores parâmetros, já a criada pelo usuário é confeccionada através de testes de limiares dos parâmetros no programa. Diversas atividades no monitoramento do Cerrado dependem de um conhecimento da distribuição espacial das fitofisionomias e do uso da terra.

2. ÁREA DE ESTUDO

A área de estudo é a cena da RapidEye 2333907 contida dentro da Estação Ecológica Serra Geral do Tocantins, na parte sul desta Unidade de Conservação (UC). Essa UC do bioma Cerrado foi criada pelo decreto de 27 de setembro de 2001 e abrange uma área aproximada de 716.306 hectares, contida dentro dos municípios de Almas, Ponte Alta do Tocantins, Rio da Conceição e Mateiros, no estado do Tocantins, e Formosa do Rio Preto, no estado da Bahia. É a segunda maior UC de proteção integral do bioma Cerrado, integrando um mosaico de áreas protegidas composto pelo Parque Estadual do Jalapão (TO), APA Estadual do Jalapão (TO), APA Federal da Serra da Tabatinga (TO) e Parque Nacional Nascentes do Rio Parnaíba (PI). Essas unidades em conjunto são alvo atualmente do Projeto Corredor Ecológico da região do Jalapão e constituem o maior fragmento de Cerrado hoje legalmente protegido (Brasil, 2001).

A região onde a Estação Ecológica Serra Geral do Tocantins está localizada apresenta praticamente todas as fitofisionomias do bioma Cerrado. As formações campestres são as mais abundantes, como o Campo Limpo e o Campo Sujo. Essas fitofisionomias, caracterizadas pela presença de um estrato gramíneo e a quase total ausência de indivíduos lenhosos, sofrem grande risco de inflamabilidade durante o período de estiagem. Nessa época do ano, principalmente no final da estação seca, o material seco acumulado funciona como combustível para incêndios de grande intensidade (Daldegan et al., 2014). O clima da região é tropical com estação seca, característico do Brasil Central. A média da precipitação anual oscila entre 1250 a 1750 mm e a temperatura média anual varia de 21°C a 25°C. O período seco se estende de meados de maio a setembro e o período chuvoso acontece entre os meses de outubro a abril (Brasil, 2014).

A UC está localizada na Bacia Sedimentar do Parnaíba entre faixas de dobramentos profundos. As formas de relevo envolvem uma sequência de chapadas e patamares em região sedimentar. Os patamares ocorrem em relevo plano ou suave ondulado, ao passo que as de chapadas

são feições tabuliformes em relevos típicos de cuestas. São comuns a presença de “inselbergs”, também conhecidos por morros testemunhos. A altitude máxima atinge valores superiores a 850 metros em alguns pontos do Chapadão Ocidental da Bahia e a altitude mínima é de 300 metros nas áreas dos patamares (Villela e Nogueira, 2011).

A Estação Ecológica Serra Geral do Tocantins foi criada com os objetivos de preservar amostras dos ecossistemas de Cerrado e propiciar o desenvolvimento de atividades de educação ambiental e pesquisas de cunho científico. A situação das estradas dentro da unidade é precária. Algumas áreas não são acessíveis por carro, o que dificulta a ação de proteção dos agentes. As principais vias de acesso se dão por estradas vicinais que saem das rodovias principais (Brasil, 2014).

A Estação Ecológica é uma categoria de unidade de conservação que não permite a presença de moradores em seu interior. Os imóveis situados dentro dos limites da Estação Ecológica Serra Geral do Tocantins estão declarados como de utilidade pública e seus moradores deverão ser desapropriados e devidamente indenizados. No entanto, a regularização fundiária ainda está em fase inicial e a consolidação territorial ainda está longe de ser concluída. Além disso, algumas famílias se declaram como parte da população tradicional “Comunidade dos Prazeres” na porção baiana da UC. Essas famílias ainda não são reconhecidas formalmente e suas principais atividades são a criação de gado e o manejo de pequenas roças. Vale salientar que a criação de gado ocorre em áreas de Cerrado e com uso de fogo (Brasil, 2014). A **figura 1** mostra a localização da cena 2333907 de 13/06/2011 do sensor RapidEye na Estação Ecológica Serra Geral do Tocantins.

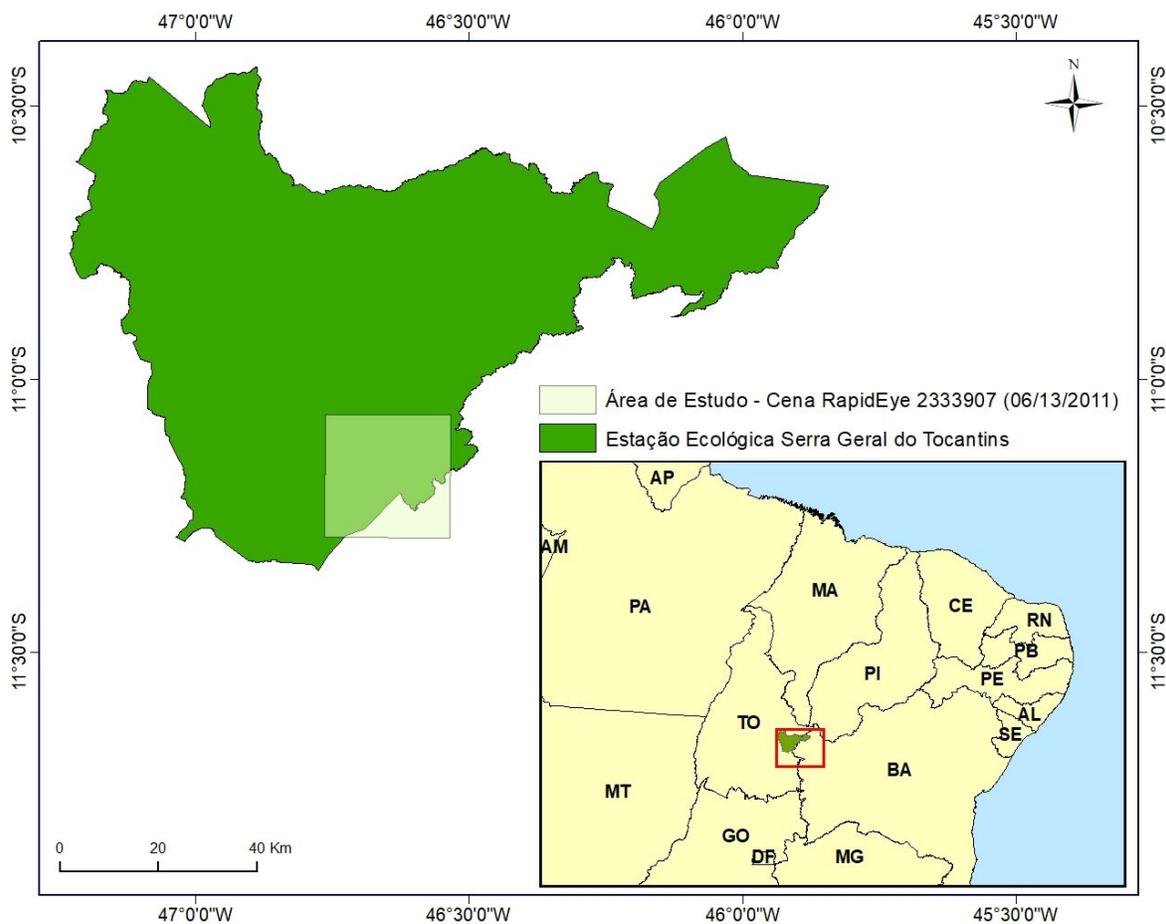


Figura 1: Mapa de Localização da Imagem RapidEye 2333907 na Estação Ecológica da Serra Geral do Tocantins.

3. MATERIAIS E MÉTODOS

A metodologia é composta pelas seguintes etapas: (a) aquisição da imagem; (b) correção atmosférica, (c) segmentação, (d) classificação usando dois métodos de árvore de decisão (algoritmo J48 e refinamento manual da árvore de decisão), e (e) análise de acurácia. A figura 2 apresenta o fluxograma do processamento digital de imagem com as distintas etapas dessa pesquisa.

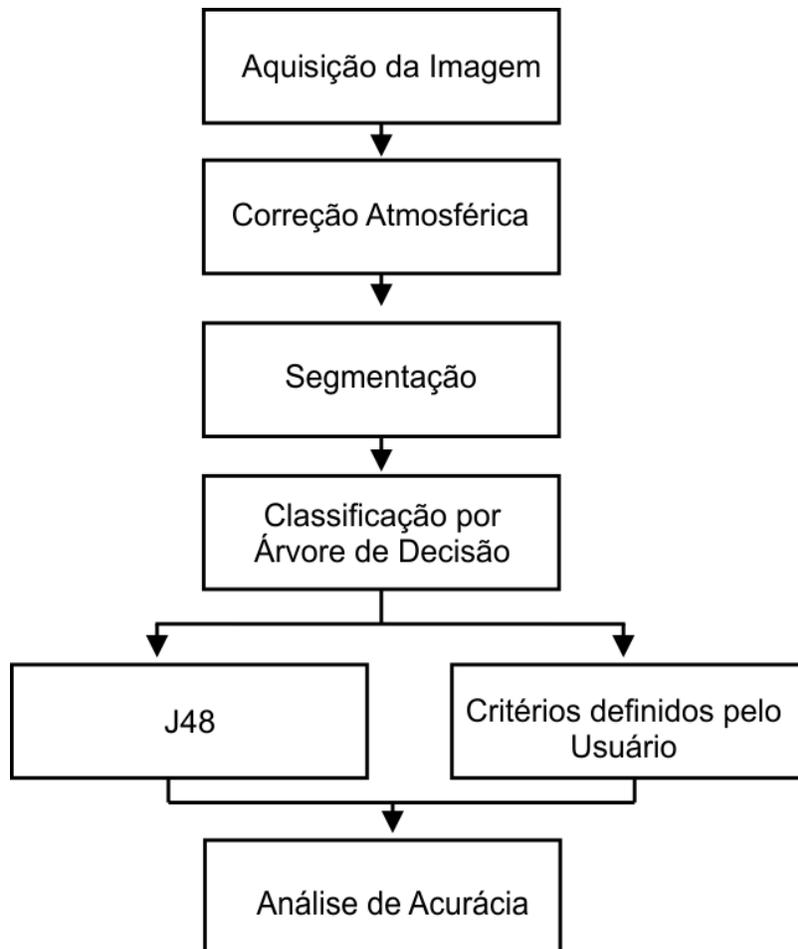


Figura 2: Fluxograma do processamento digital de imagem da imagem Rapideye.

3.1. Imagens RapidEye

O planejamento do programa RapidEye começou no final da década de 90. Após passar por uma fase de testes, tornou-se operacional em fevereiro de 2009. As imagens RapidEye possuem resolução espacial de cinco metros, resolução radiométrica de doze bits por pixel e cinco bandas espectrais: azul (440-510nm), verde (520-590nm), vermelho (630-685nm), vermelho limítrofe (red-edge) (690-730nm) e infravermelho próximo (760-850nm) (Rapideye AG, 2007). Essas imagens são provenientes de uma constelação de cinco satélites equipados com um sensor multi-espectral composto por scanners de linha com 12000 pixels cada (Anderson et al., 2013).

A constelação de satélites RapidEye estabelece operações eficientes e acuradas dos alvos da superfície terrestre, revisitando o mesmo lugar na Terra em um período de 5,5 dias (Krischke et al., 2000). A capacidade de revisita é baseada em uma órbita heliosíncrona, um caso particular de uma órbita quase polar em que o satélite viaja do pólo norte ao pólo sul e vice-versa. Esse é um mecanismo que garante com que o satélite sempre passe pelo mesmo ponto da superfície terrestre (Stoll et al., 2013). O sensor RapidEye mantém padrões rigorosos de calibração e continuamente esforça-se para melhorar todos os seus processos (Anderson et al., 2013).

As imagens RapidEye tem servido para uma série de aplicações dentro do sensoriamento remoto, principalmente em trabalhos que necessitam de imagens com alta resolução espacial. Carvalho et al (2014) usaram imagens RapidEye para desenvolver uma análise do uso e ocupação da terra na Fazenda Boa Vista, Distrito Federal, a fim de comparar o processamento de dados orientado a objeto de dois softwares, o InterImage e o SPRING. Constatou-se que ambos os softwares resultaram em excelentes classificações. Souza et al (2012) conduziu um estudo para avaliar o algoritmo de segmentação multi-resolution no mapeamento da vegetação usando OBIA com a banda Red Edge (Vermelho-limítrofe) da RapidEye. Esse estudo realizou uma amostragem de 800 objetos e verificou que o canal Red Edge era adequado ao mapeamento da vegetação. Ramoelo et al. (2012) utilizou a RapidEye, especialmente a banda Red Edge, para estimar a quantidade de nitrogênio em coberturas florestais. É importante ressaltar que muitas pesquisas

adotam no processamento digital das imagens RapidEye a segmentação e a análise baseada em objetos (Adamczyk & Osberger, 2015; Dupuy et al., 2012; Elatawneh et al., 2014; Hou & Walz et al., 2014).

A imagem RapidEye foi corrigida atmosféricamente com a ferramenta ATCOR (Richter, 1997). Essa ferramenta considera o efeito da topografia e utiliza as bandas termais. Assim, o método ameniza a influência da atmosfera, iluminação solar, geometria de vista do sensor e informação do terreno. Apesar de uma grande quantidade de informações dos alvos nas imagens de satélites poderem ser extraídas sem correção atmosférica, o modelo físico implementado no ATCOR oferece maiores vantagens, principalmente quando se lida com dados multitemporais e quando se compara imagens de diferentes sensores (Richter, 1997).

Nesse trabalho foi utilizada a cena 2333907 da RapidEye, de uma área de dentro da Estação Ecológica Serra Geral do Tocantins, do dia 13/06/2011 referente ao início da estação seca, pois não possui presença de cobertura de nuvem. Inicialmente, a aplicação dos parâmetros e limiares das árvores de decisão utilizou parte dessa imagem para teste. Posteriormente, foi adotado e aplicado o esquema de classificação para a imagem inteira. As imagens sofreram correção atmosférica para remover seus efeitos atmosféricos e obter os valores relativos à reflectância dos alvos.

3.2. Segmentação da Imagem

O programa utilizado foi o InterImage que possui código aberto escrito em C++ e Qt e permite interpretação automática de imagens a partir de classificação orientada a objeto. O InterImage faz parte de um projeto de cooperação científica internacional liderada pelo Laboratório de Visão Computacional do Departamento de Engenharia Elétrica da Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio) e pelas divisões de Processamento de Imagens e de Sensoriamento Remoto do Instituto Nacional de Pesquisas Espaciais (INPE) (Manual InterImage, 2016).

O método OBIA consiste basicamente de duas etapas: segmentação e classificação. Um princípio fundamental da classificação orientada a objetos é segmentar a imagem em regiões (Addink et al., 2012). Os objetos são áreas homogêneas compostas por agrupamentos de pixels com semelhança espectral, que apresentam atributos espaciais como forma, tamanho, contexto e relação de vizinhança (Dezsö et al., 2012). O valor espectral do objeto torna-se o valor médio de todos os pixels existentes dentro dele.

O algoritmo utilizado para segmentar a imagem foi o *TA Baatz Segmentator* (Baatz & Schöp, 2000), um método *multi-resolução* que gera objetos cujo o tamanho é definido pelo grau de heterogeneidade dos pixels dentro do objeto (Rittl et al., 2013). A abordagem *multi-resolução* tem provado ser uma das melhores estratégias de segmentação (Witharana & Civco, 2014). A decisão de agrupamento é baseada no critério local de homogeneidade, que é descrito pela similaridade dos objetos adjacentes. Nesse processo, todas as áreas da imagem são levadas em consideração (Baatz & Schöp, 2000).

A segmentação pode ser feita em diversas escalas e tamanhos (Addink et al., 2012). Objetos grandes correspondem a regiões mais heterogêneas, ou seja, menos semelhantes entre si, ao passo que, objetos pequenos correspondem a objetos mais homogêneos, com pixels com valores espectrais mais próximos. Não existe um método amplamente aceito e disponível para avaliar qual é a escala ideal de segmentação, pois ela varia de acordo com os diferentes tipos de classificações, tipos de sensores e ecossistemas. Ao operador é permitido refazer o processamento até encontrar uma segmentação ideal. Esse é um dos motivos pelo qual o OBIA tem feito tanto sucesso (Myint et al., 2011). Além da escala, outros parâmetros podem influenciar na maneira como a imagem é segmentada. O algoritmo dá a opção de escolher os pesos das bandas que serão levados em consideração na segmentação e a incorporação de arquivos auxiliares tanto vetoriais como raster (Myint et al., 2011).

O processo de segmentação pode ser descrito como uma técnica de agrupamento por região *Top-Down* ou *Bottom-up*. No método *top-down*, a segmentação começa com a imagem toda

sendo um objeto e nos próximos níveis de segmentação, o objeto (que é a imagem toda) é segmentado em objetos menores. No método *bottom-up*, ocorre o processo inverso, cada pixel é um objeto no primeiro nível e os pixels se juntam aos pixels vizinhos nos níveis seguintes para formarem objetos maiores (Dezsö et al., 2012; Ma et al., 2015). Dentro do segmentador, além da escala, é possível determinar outros parâmetros que vão diferenciar a formação dos objetos: compactação e cor. A Compactação determina as fronteiras do objeto e qual a sua transição para os objetos vizinhos. A cor determina quão relevante é o valor espectral dos pixels na formação do objeto (Costa e Cazes, 2010). A classificação por árvore de decisão utilizou a segmentação Ta Baatz Segmenter na escala 100, com compactness weight: 0.5 e color weight: 0.8.

A figura 3 mostra os parâmetros de segmentação utilizados no processo de classificação da imagem. Os parâmetros considerados são: a) as cinco bandas da RapidEye possuindo um mesmo peso de prioridade; b) compactação dos segmentos de 0.5; c) peso da cor (informação espectral) de 0.8; d) escala de 100; e) confiabilidade de 0.2; e g) Distância euclidiana de 20. Estes parâmetros foram estabelecidos após uma série de testes. Os objetos resultantes dessa segmentação foram os mais representativos para a metodologia desta dissertação.

TopDown Operator	TA_Baatz_Segmenter
BottomUp	
TopDown	
a) Input Image	img
a1) Input Bands (co...	0,1,2,3,4
a2) Input Weights (...)	1,1,1,1,1
b) Compactness W...	0.5
c) Color Weight	0.8
d) Scale Parameter	100
e) Use Optimization	no
f) Reliability	0.2
g) Euclidean Distan...	20

Figura 3: Parâmetros da Segmentação na Imagem

A figura 4 apresenta a imagem RapidEye segmentada com escala de 100, onde os polígonos transparentes representam os objetos da imagem. Os pixels dentro dos segmentos são agrupados pelo grau de semelhança. É notória a formação de polígonos formados apenas por pixels de vegetação mais densa (aparece em vermelho na imagem). Enquanto, os pixels de vegetação menos densa (que não apresentam uma coloração de vermelho) agrupam-se entre si formando objetos.

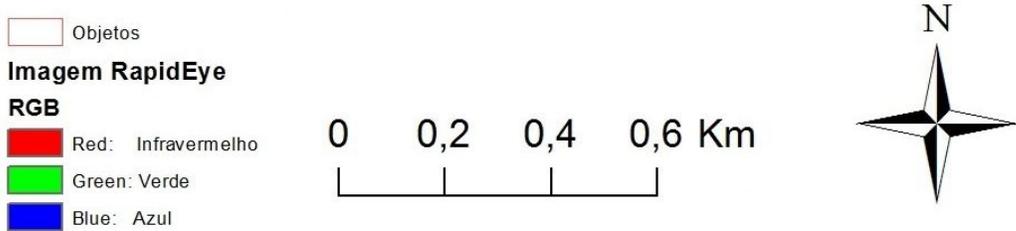
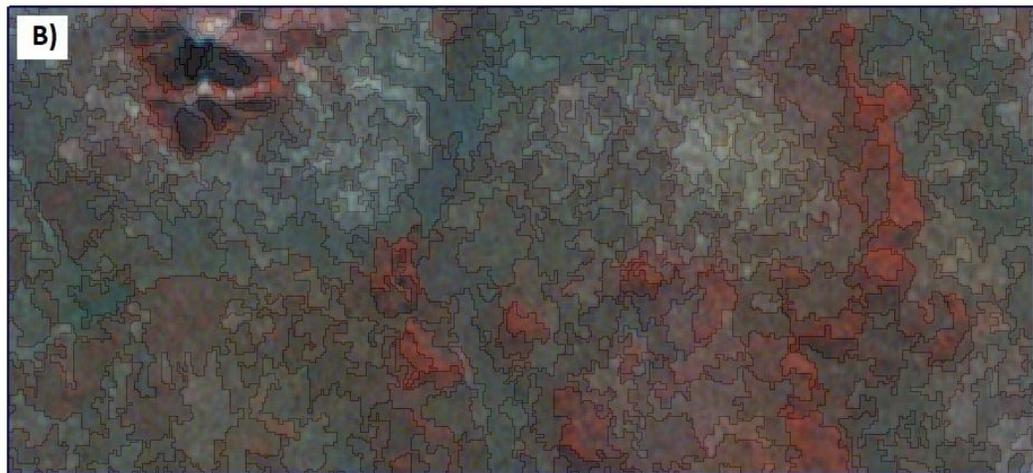
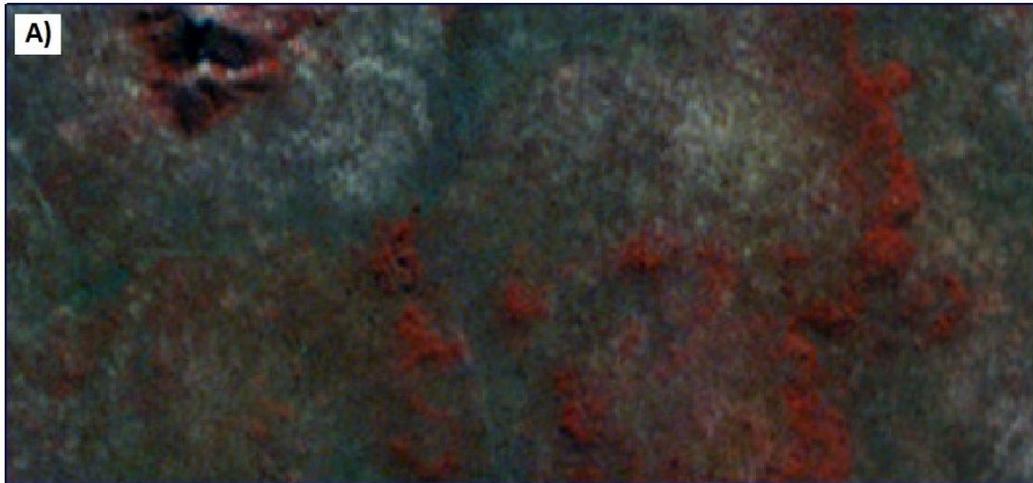


Figura 4: a) composição colorida RGB (5-2-1), b) imagem segmentada.

3.3. Classificação usando Árvore de Decisão

A árvore de decisão efetua uma divisão do conjunto de dados com o propósito de que cada subconjunto proveniente desse particionamento contenha casos de uma única classe (Friedl e Brodley, 1997). A construção de uma árvore de decisão é composta pelas seguintes feições (Latorre et al., 2007): (a) um nó raiz formado a partir de todos os dados, (b) um conjunto hierárquico de nós internos denominados partições que estabelece a tomada de decisão a partir de critérios para definir o próximo nó descendente ou filho, e (c) nós terminais, denominados de folhas, que não possuem nó descendente. Portanto, a árvore de decisão efetua uma divisão binária em cada nó intermediário estabelecendo dois nós descendentes: (a) um que satisfaz o teste lógico, e (b) outro que não satisfaz (Friedl et al., 1999; Latorre et al., 2007). Esse método permite classificar dados de forma individualizada e sequencial.

O estabelecimento de uma acurada árvore de decisão está na capacidade do algoritmo de crescer e podar a árvore, estabelecendo um número adequado de atributos e valores de cortes. Portanto, uma árvore é acrescida e podada até que todas as observações de treinamento sejam corretamente classificadas dentro de uma estrutura de divisões hierárquicas. Normalmente, esse procedimento resulta na redução da quantidade de nós das árvores, evitando complexidades desnecessárias. A partir do estabelecimento de uma árvore de decisão, pode-se utilizá-la para classificar novos casos similares (Friedl & Brodley, 1997). A figura 5 apresenta como é a estrutura de uma árvore de decisão. Os círculos maiores representam os nós que são onde cada parâmetro se encontra dentro da árvore. Em verde com os sinais de positivo e negativo está representado o pertencimento para cada uma das classes presentes na árvore de decisão.

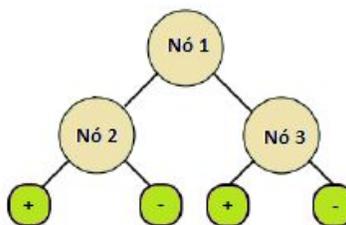


Figura 5: Representação da Estrutura da Árvore de Decisão

Um importante fator na construção de uma árvore de decisão é o conjunto de atributos que descrevem as classes. Neste mapeamento da vegetação pelas imagens RapidEye, diferentes atributos foram utilizados com o propósito de distinguir as classes: médias das bandas (1, 2, 3, 4 e 5), variância das bandas 3 e 5, brilho, e os índices espectrais Normalized Difference Vegetation Index (NDVI), Enhanced Vegetation Index (EVI) e Normalized Difference Water Index (NDWI). As médias das bandas (1, 2, 3, 4 e 5) correspondem ao valor médio para cada banda de todos os pixels pertencentes a determinado objeto. O brilho é calculado pela soma do valor espectral de cada banda do objeto (o valor espectral do objeto é a média de todos os seus pixels) dividido pelo número total de bandas (Rittl et al., 2013). A tabela 1 apresenta as formulações dos índices espectrais utilizados.

Tabela 1: Formulação dos índices espectrais, onde NIR é infravermelho próximo, SWIR é infravermelho de ondas curtas, Red é a faixa do vermelho, Blue é a faixa do azul.

NDVI	$NDVI = \frac{NIR -}{NIR +}$	Rouse et al., (1974)
NDWI	$NDWI = \frac{NIR - SWIR}{NIR + SWIR}$	Gao et al, (1996)
EVI	$EVI = G \frac{NIR -}{NIR + C1xRed - C2xBlue + L}$ onde $G = 2,5; L = 1; C1 = 6; C2 = 7.5$	Huete et al., (2002)

Dois métodos de árvore de decisão foram adotados: (a) algoritmo J48, e (b) construção da árvore de decisão pelo próprio usuário. A classificação pela árvore de decisão J48 (Quinlan, 1993) utilizou o programa de mineração dos dados Waikato Environment for Knowledge Analysis (WEKA) (Hall et al. 2009), um aplicativo Java de código aberto produzido pela universidade de Waikato na Nova Zelândia.

O algoritmo J48 é um classificador supervisionado, onde é necessário o fornecimento de amostras para a realização da classificação. O J48 é uma modificação do algoritmo C4.5 (Quinlan, 1996). Na escolha do atributo, este algoritmo considera todas as possibilidades de testes que podem

dividir o conjunto de dados e seleciona o melhor entre eles (Zhao e Zhang, 2007). O atributo que melhor particiona cada nó da árvore é selecionado pelo critério do ganho de informação normalizado, também conhecido por diferença em entropia. Nas próximas etapas este processo se repete para as partições de nós menores (Quinlan, 1996). O C4.5 performa árvores de decisão tanto em atributos contínuos quanto atributos em discretos. Os discretos são como a cor dos olhos tendo um único valor para “azul”, “castanho”, “verde”, etc, ao passo que os atributos contínuos são valores contínuos como o peso e altura das pessoas. Quinlan (1993) argumenta que o C4.5 tem uma melhor performance em domínios com preponderança de atributos contínuos. Além do J48, outros algoritmos como o RandomTree, o Random Forest, o NBTree também são fornecidos para minerar os dados no WEKA (Zhao e Zhang, 2007). O J48 foi escolhido pois este é um algoritmo rápido de se treinar e gera bons resultados, sendo um dos mais utilizados dentro dos mineradores de dados.

A seleção de amostras de objetos para a árvore de decisão considerou locais representativos de cada classe por meio da interpretação visual da composição colorida RGB das bandas 5-2-1. Segundo Ma (2015), a quantidade de amostras deve representar adequadamente cada classe. Assim, consideramos 30 amostras de cada classe para a classificação. Após a seleção de amostras, o minerador J48 retorna com a árvore de decisão no qual cada objeto pertence a apenas uma classe. O minerador de dados estabelece quais os atributos que devem ser usados na classificação e os valores limites desses atributos que separam os segmentos em classes distintas. A figura 6 apresenta um exemplo de seleção de objetos amostrais que foram levados para a mineração de dados.

A diferenciação das classes considerou uma análise quantitativa da vegetação fotossinteticamente ativa que é realçada pela banda do infravermelho próximo. Essa abordagem não é adequada na presença de Mata Seca por ser uma fitofisionomia com predomínio de árvores caducifólias, que perdem sua folhagem durante a estação seca. Portanto, a diferenciação por vegetação fotossinteticamente ativa mostrou-se adequada por existir Mata Seca na imagem em análise e por ser a data da imagem do início da estação seca (início de junho). No caso de haver Mata Seca na região, uma possível diferenciação dela para outras formações florestais poderia ser

através da textura presente nos objetos. A textura se diferencia de acordo com variação dos valores espectrais dos pixels contidos no objeto.

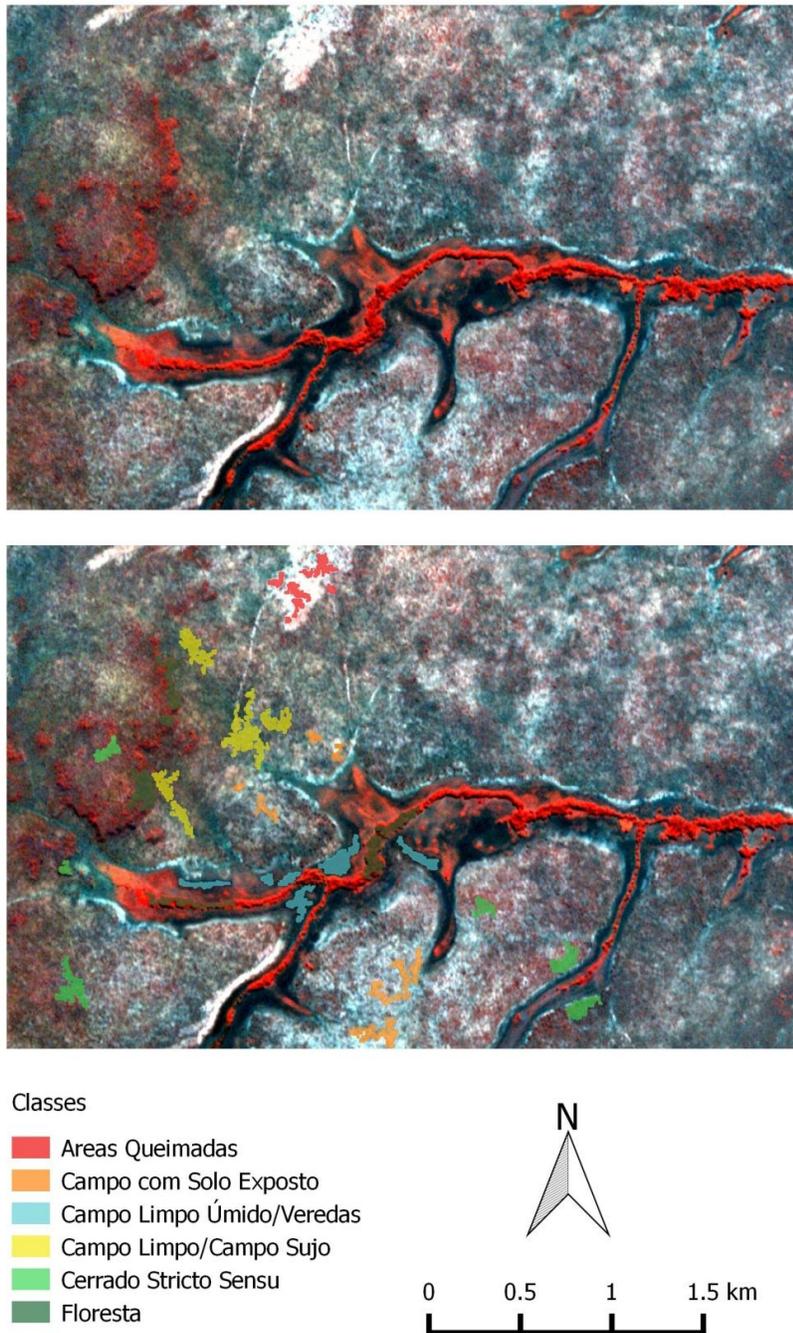


Figura 6: a) Composição colorida RGB (5-2-1) da imagem RapidEye, b) Seleção de objetos amostrais para treinar a árvore de decisão J48.

Complementarmente, nós construímos uma árvore de decisão própria a partir de testes dos diversos parâmetros e índices, considerando os limiares mais satisfatórios para a distinção das classes. Este procedimento permitiu ajustar manualmente os critérios e limiares para a separação das classes, que é uma vantagem por adicionar o conhecimento local na análise. O InterImage possui uma interface que permite que o usuário faça estes testes até encontrar os resultados mais satisfatórios para preencher a sua própria árvore de decisão.

3.4. Definição das Classes de Fitofisionomias do Cerrado

As classes adotadas no mapeamento foram baseadas no mapeamento de dois projetos do SEPLAN: (a) Projeto de Desenvolvimento Regional Sustentável: mapeamento das regiões fitoecológicas e inventário florestal do estado do Tocantins; e (b) Mapeamento das regiões fitoecológicas e inventário florestal do estado do Tocantins. Esses dois mapeamentos serviram apenas de auxílio para a escolha das classes. Dentro das diversas classes, as escolhidas no trabalho foram aquelas fitofisionomias possíveis de serem mapeadas pela metodologia aplicada. As classes definidas para a presente pesquisa são: Campo com Solo Exposto, Campo Limpo/Sujo, Cerrado Stricto Sensu (compreende Cerrado Ralo, Cerrado Típico e Cerrado Denso), Floresta (compreende Cerradão e Mata de Galeria/Mata Ciliar), Campo Limpo Úmido/Veredas e Áreas Queimadas. Abaixo segue uma breve descrição das fitofisionomias do bioma Cerrado consideradas nesta dissertação:

- Campo Limpo Úmido/Veredas: são regiões campestres com gleissolos e passível de alagamento na estação chuvosa, que normalmente acompanham as drenagens e possuem a presença de palmeiras como o Buriti.
- Floresta: são regiões florestais encontradas no bioma Cerrado. Não foi possível diferenciar Mata de Galeria/Mata Ciliar de Cerradão por intermédio do sensoriamento remoto. Mesmo aplicando parâmetros como textura, os erros de distinção entre estas duas fitofisionomias

foram maiores que o esperado. Deste modo, foi utilizado a classe “Floresta” para compreender estas duas formações:

- Mata de Galeria/Mata Ciliar: são as matas que seguem os cursos d'água. A Mata Ciliar é caracterizada pela não formação de galerias devido a largura mais extensa dos rios. A Mata de Galeria, por sua vez, é encontrada em cursos d'água de menor largura, o que possibilita a formação de galerias, ou seja, as matas das duas margens se encontram formando corredores fechados. No sensoriamento remoto, especificamente, nesse trabalho, não foi possível separar essas duas formações, e, por isso, elas foram tratadas uma única fitofisionomia.
- Cerradão: ao contrário das outras fitofisionomias do cerrado, o Cerradão é uma formação florestal que apresenta dossel contínuo. O dossel tem, em média, 12 metros de altura. As espécies de árvores emergentes podem atingir mais de 15 metros.
- Campo Limpo/Campo Sujo: o campo limpo é uma fitofisionomia campestre com a presença predominante de herbáceas, pequena quantidade de arbustos e ausência total de formação arbórea. O campo sujo permite uma quantidade maior de arbustos e subarbustos e a presença bastante esparsada de indivíduos menos desenvolvidos das espécies arbóreas. Apesar da resolução espacial de cinco metros, alguns alvos como arbustos requerem uma resolução ainda melhor para serem identificados. Neste sentido, não foi possível fazer a diferenciação destas duas fitofisionomias através do sensoriamento remoto, e, portanto, foi estabelecido uma única classe contemplando as duas formações.
- Campo com Solo Exposto: esta classe contempla as áreas de campo que possuem uma grande exposição de solo. Na imagem, essas áreas apresentam um brilho bastante intenso, parecido com o solo após uma queimada.

- Cerrado Stricto Sensu: compreende Cerrado Ralo, Cerrado Típico e Cerrado Denso que são fitofisionomias de savana que se diferem de acordo com a sua densidade arbórea. Mesmo a RapidEye sendo de alta resolução espacial, não foi possível distinguir entre as três subclasses do Cerrado Stricto Sensu por haver uma diferença muito sutil em imagens com pixels de cinco metros de resolução, o que mostra uma limitação desse tipo de imagem para este mapeamento.
 - Cerrado Ralo: é caracterizado por ser uma fitofisionomia com cobertura arbórea maior que a do Campo sujo, contendo um estrato arbóreo que varia de 5 a 20%.
 - Cerrado Típico: é uma fitofisionomia do cerrado arborizado associada aos ambientes de Cerrado Ralo e Cerrado Denso. É a transição entre essas duas fitofisionomias. É caracterizado por um denso estrato rasteiro de herbáceas e arbustos, e a presença de árvores esparsadas ou mais agrupadas. A composição arbórea é mais densa que a do Cerrado Ralo.
 - Cerrado Denso: essa fitofisionomia apresenta um estrato herbáceo rasteiro e uma quantidade de árvores maior e mais fechada que a do Cerrado Típico.
- Áreas Queimadas: correspondentem às cicatrizes de incêndio e que não permitem a classificação adequada em outras fitofisionomias devido ao valor de brilho que estas áreas possuem. Esta situação impede que os parâmetros e limiares consigam fazer a distinção das classes corretamente.

A figura 7 apresenta uma seleção de fotos tiradas em trabalho de campo na Estação Ecológica Serra Geral do Tocantins, que ilustram a vegetação do bioma Cerrado.

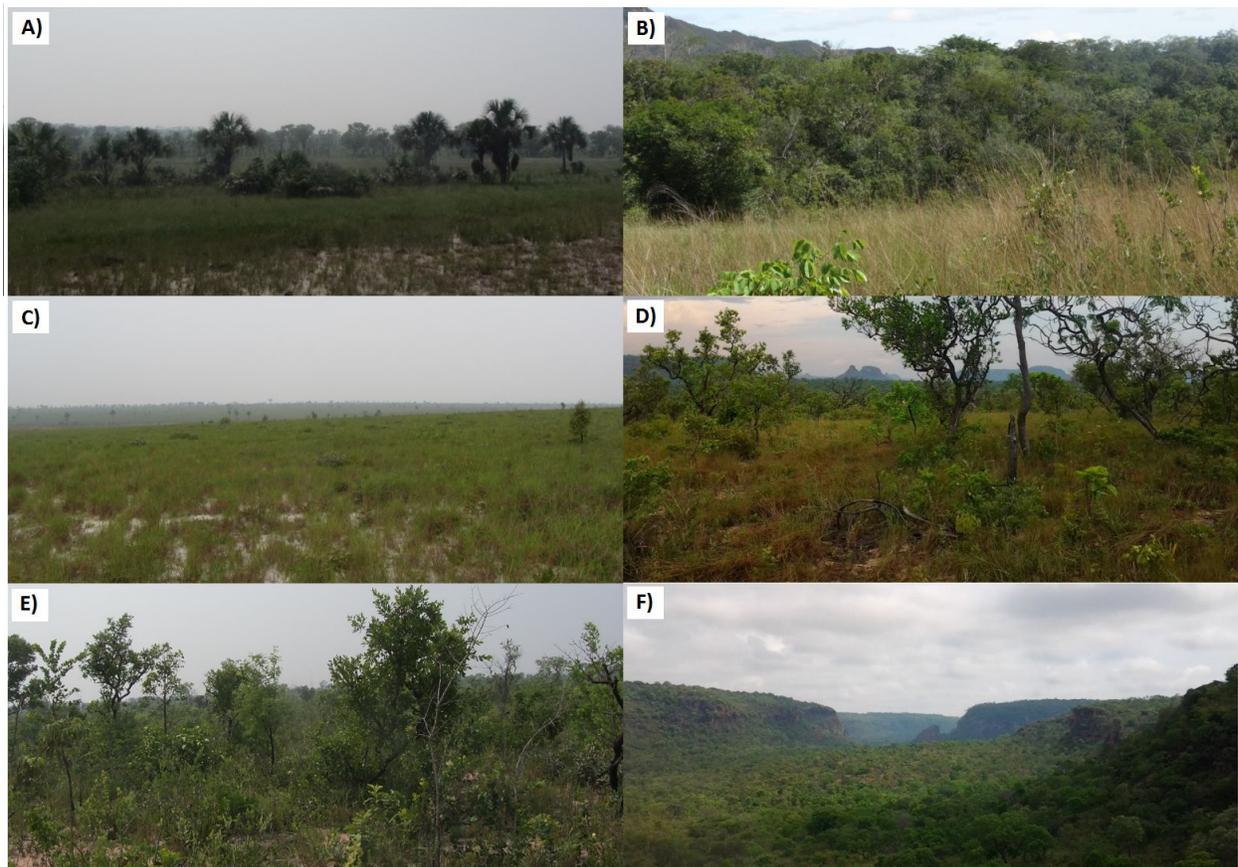


Figura 7: Fotos das Fitofisionomias do Bioma Cerrado: a) Campo Limpo Úmido/Veredas; b) Mata de Galeria; c) Campo Limpo; d) Cerrado Ralo; e) Cerrado Típico e f) Cerradão.

3.5. Análise de Acurácia

Apesar das técnicas de classificação terem considerável potencial no mapeamento de imagens de sensoriamento remoto, inúmeros problemas são constantemente encontrados e que resultam em erros. Portanto, os mapeamentos por imagens de satélite necessitam de informações sobre a sua acurácia, especialmente para avaliá-los e refiná-los a fim de se obterem melhores resultados (Foody, 2004, 2002).

Na análise de acurácia foram utilizados a matriz de confusão para calcular a acurácia total (pode ser expressado em porcentagem) e o índice Kappa (Congalton & Green, 1999). É obtida a quantidade de acertos das classificações de acordo com a concordância entre os alvos comparados (Trodd, 1995). A matriz de confusão, também conhecida como matriz de erros, é uma tabela

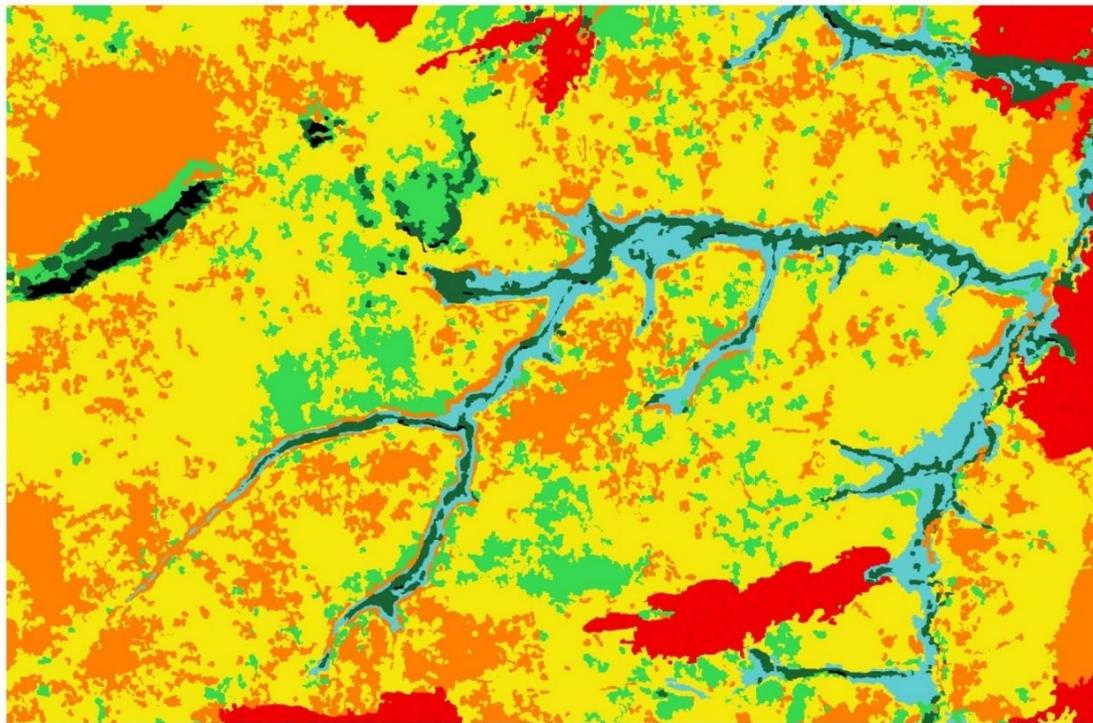
simples de cruzamentos de dados entre atributos. Dessa matriz, uma série de medições podem ser derivadas para descrever a acurácia de um mapa temático em relação a um mapa verdade. A importância dessas medições é muito grande para determinar a capacidade de mapeamento de diferentes técnicas de classificação em sensoriamento remoto (Foody, 2004).

A acurácia total (overall) é calculada pela soma do número de pixels classificados corretamente dividido pelo total do número de pixels da imagem. Já o coeficiente Kappa (K) é uma medida de acurácia para classificação descrita pela seguinte formulação matemática:

$$K = \frac{m \sum_{i=1}^r S_{ii} - \sum_{i=1}^r S_{i+} S_{+i}}{m^2 - \sum_{i=1}^r S_{i+} S_{+i}}$$

Nesta equação, o “r” é o número de linhas na matriz de erros, “S_{ii}” é o número de observação na linha “i” e coluna “i”, “S_{i+}” e “S_{+i}” são, deste modo, os totais na linha “i” e coluna “i”, respectivamente, e “m” é o número total de observações. Uma vez que o valor limiar é definido para uma área representativa, pode-se aplicar para a totalidade da imagem. Os valores do índice Kappa variam no intervalo de -1 a 1. Valores abaixo de 0 apresentam concordância quase inexistente, de 0 a 0,20 pequena, de 0,21 a 0,40 insatisfatória, de 0,41 a 0,60 satisfatória, de 0,61 a 0,80 substancial e de 0,81 a 1,00 quase perfeita (Landis & Koch, 1977).

A análise de acurácia das duas classificações produzidas neste trabalho foi realizada por intermédio de uma comparação entre elas e uma outra classificação produzida por interpretação visual de uma área amostral da cena da RapidEye utilizada, a qual foi denominada de imagem verdade (figura 8). Foi usado o plug-in do software QGIS chamado de Accuracy Assessment. Este plug-in gera uma tabela com uma matriz de confusão possível de ser exportada para o Excel para que os cálculos dos índices sejam aplicados.



Classes

- Áreas Queimadas
- Campo Limpo/Sujo
- Campo com Solo Exposto
- Cerrado Stricto Sensu
- Floresta
- Sombra
- Campo Limpo Úmido/Veredas

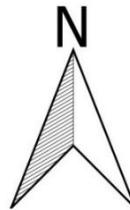


Figura 8: Imagem Verdade.

Primeiramente, a imagem verdade foi segmentada com os mesmos parâmetros utilizados nas duas classificações feitas neste trabalho, pois desse modo sabe-se que a sua tematização será executada exatamente através dos mesmos objetos. Esses objetos foram exportados em um arquivo vetorial no formato shapefile e lavado para o ArcGIS a fim de serem analisados em um software com ambiente de SIG. Na tematização desta imagem verdade não foram usados nenhuma regra preestabelecida para as classes, exceto para as Áreas Queimadas, cujo processo será detalhado mais a frente. Todos os objetos foram analisados individualmente e assinalados manualmente para uma classe de acordo com uma interpretação visual e com o conhecimento local do analista. A

determinação de qual classe de cerrado cada objeto deve pertencer foi determinada através da densidade de indivíduos lenhosos dentro do objeto. Para facilitar essa distinção faz-se uma composição colorida RGB onde se coloca o infravermelho próximo na banda vermelha, o verde na banda verde e o azul na banda azul (composição 5-2-1 da RapidEye). Deste modo a vegetação fotossinteticamente ativa se destaca com uma coloração avermelhada e facilita a distinção da densidade arbórea na imagem.

Para a classe Áreas Queimadas usou-se os arquivos vetoriais das áreas queimadas produzidos pelo INPE para os anos de 2010 e 2011. Esses arquivos serviram apenas como auxílio para guiar o discernimento dos objetos pela interpretação visual. Os objetos de áreas queimadas possuem uma diferenciação grande no tom de sua cor pois depende da época em que a queima ocorreu. Por exemplo, uma área queimada há poucas semanas da data da imagem apresenta um brilho muito mais intenso que uma área queimada um ano antes. O solo de uma queimada recente se apresenta demasiadamente exposto pois o estrato de gramínea foi consumido pelo incêndio.

4. RESULTADOS

4.1 Resultado da classificação usando a árvore de decisão J48

A figura 9 mostra o resultado da Árvore de Decisão J48. O minerador J48 selecionou os seguintes atributos como os mais relevantes para a distinção das classes: média da banda 5, o índice de vegetação NDVI e o brilho. Dessa forma, o minerador reduz ao máximo os parâmetros e as complexidades dentro de suas árvores de decisão.

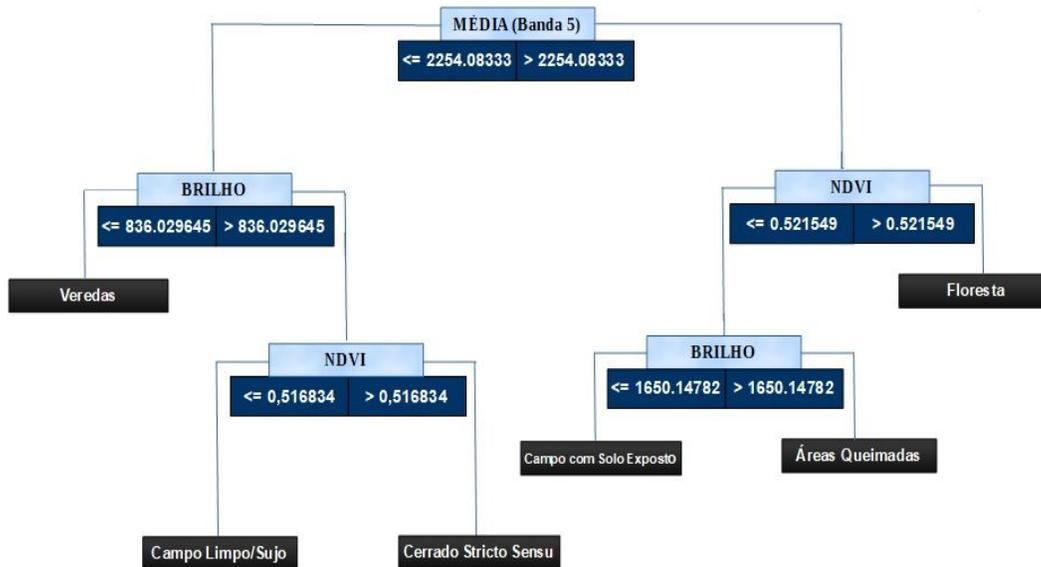
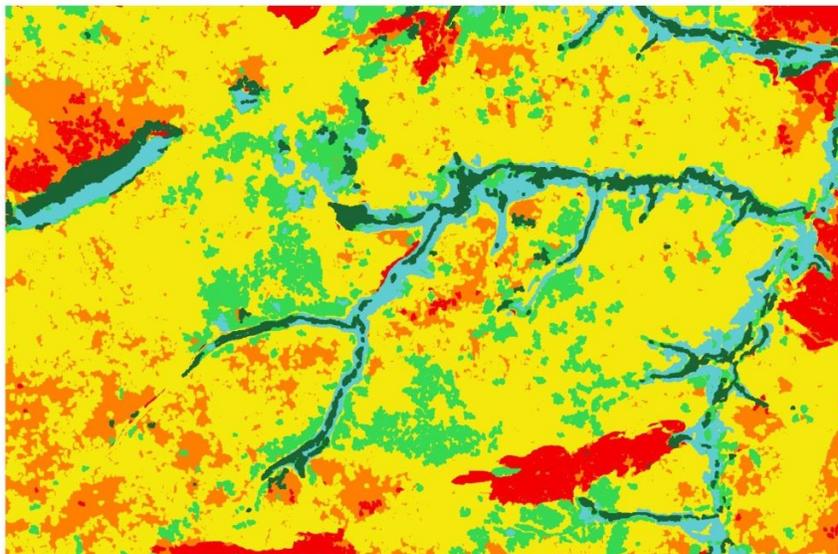
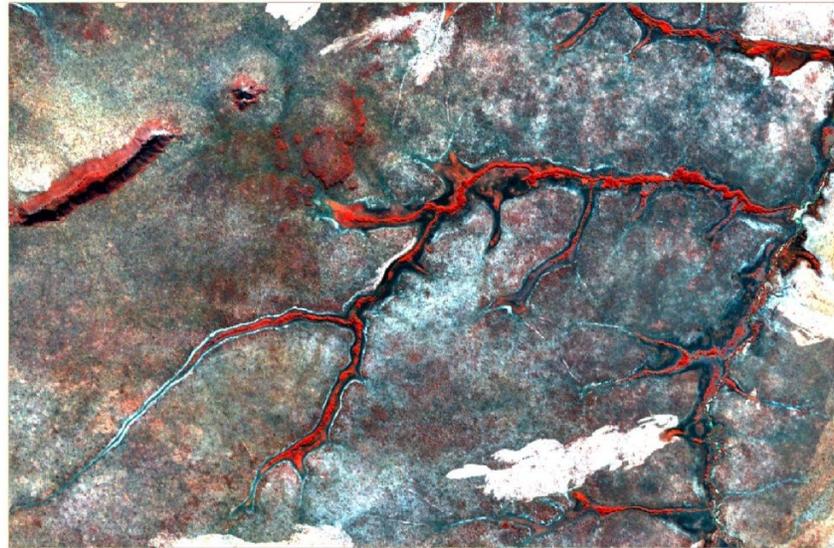


Figura 9: Árvore de Decisão usando o J48.

A figura 10 mostra o resultado da classificação pelo método J48 aplicado sobre uma área amostral da imagem RapidEye cena 2333907 de 13/06/2011. Nessa classificação, o minerador distingue dois grupos de classes em relação à média da banda 5: (a) maior que 2254,083333 (valor de reflectância multiplicado por 10.000) que inclui as classes Florestas e Áreas Queimadas e Campo

com Solo Exposto e (b) menores que 2254,083333 incluindo às classes Campo Limpo Úmido/Veredas, Campo Limpo/Campo Sujo e Cerrado Stricto Sensu.



Classes

- Áreas Queimadas
- Campo Limpo/Sujo
- Campo com Solo Exposto
- Cerrado Stricto Sensu
- Floresta
- Campo Limpo Úmido/Veredas

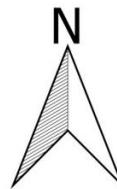


Figura 10: a) Composição colorida RGB (5-2-1) da imagem RapidEye, b) Classificação de área amostral de acordo com a árvore de decisão J48.

A separação entre as Florestas, Áreas Queimadas e Campo com Solo Exposto se dá pelos valores de NDVI maiores e menores que 0.521549. O Campo com Solo Exposto se distingue das Áreas Queimadas pelo limiar de 1650.14782 do parâmetro brilho. No outro braço da árvore de decisão, a classe de Campo Limpo Úmido/Veredas é estabelecida quando são satisfeitas duas regras: média da banda 5 menor que 2254,08333 e brilho menor que 836,029645 (valor de reflectância multiplicado por 10.000). Campo Limpo/Campo Sujo e Cerrado Stricto Sensu são os objetos com valores da Média 5 menores que 2254,08333, valores de brilho maiores que 836,029645 e entre eles a separação ocorre pelo limiar de 0,516834.

A tabela 2 apresenta a matriz de confusão entre a Imagem Verdade e a classificação J48. Com a finalidade de evitar grandes confusões e complexidades desnecessárias em troca de um resultado pouco satisfatório, as sombras foram desconsideradas sendo classificadas como Campo Limpo Úmido/Veredas.

Tabela 2: Matriz de confusão da classificação usando a árvore de decisão J48.

Índice Kappa = 0,704 Acurácia Total = 0,814		Imagem Verdade						Total	Acurácia
		Áreas Queimadas	Campo Limpo/Sujo	Campo com Solo Exposto	Cerrado Stricto Sensu	Floresta	Veredas		
Classificação J48	Áreas Queimadas	335106	16042	190112	164	0	0	541424	62
	Campo Limpo/Sujo	12068	4521146	500970	1519	0	4864	5040567	90
	Campo com Solo Exposto	71035	371717	1259984	487	0	0	1703223	74
	Cerrado Stricto Sensu	0	59702	7472	652655	49230	19503	788562	83
	Floresta	0	604	0	62197	218747	90265	371813	59
	Veredas	0	103991	2491	96989	7125	343815	554411	62
	Total	418209	5073202	1961029	814011	275102	458447	9000000	
	Acurácia	80	89	64	80	80	75		81

A árvore de decisão foi aplicada para a área total da imagem RapidEye com o corte para o limite da Estação Ecológica Serra Geral do Tocantins. Devido à incapacidade de processamento do programa InterImage, ficou inviável a aplicação para toda a área correspondente a esta Unidade de Conservação. A árvore de decisão gerada pode ser aplicada em outras imagens de datas diferentes, no entanto, é necessário fazer ajustes nos limiares dos parâmetros. Para imagens da estação chuvosa não se recomenda aplicar tal metodologia pois a resposta espectral não permite uma boa distinção dos alvos, além da grande presença de nuvens. A figura 11 apresenta o mapa da classificação aplicada para toda a cena 2333907 de 13/06/2011 com o recorte do limite da Estação Ecológica Serra Geral do Tocantins.

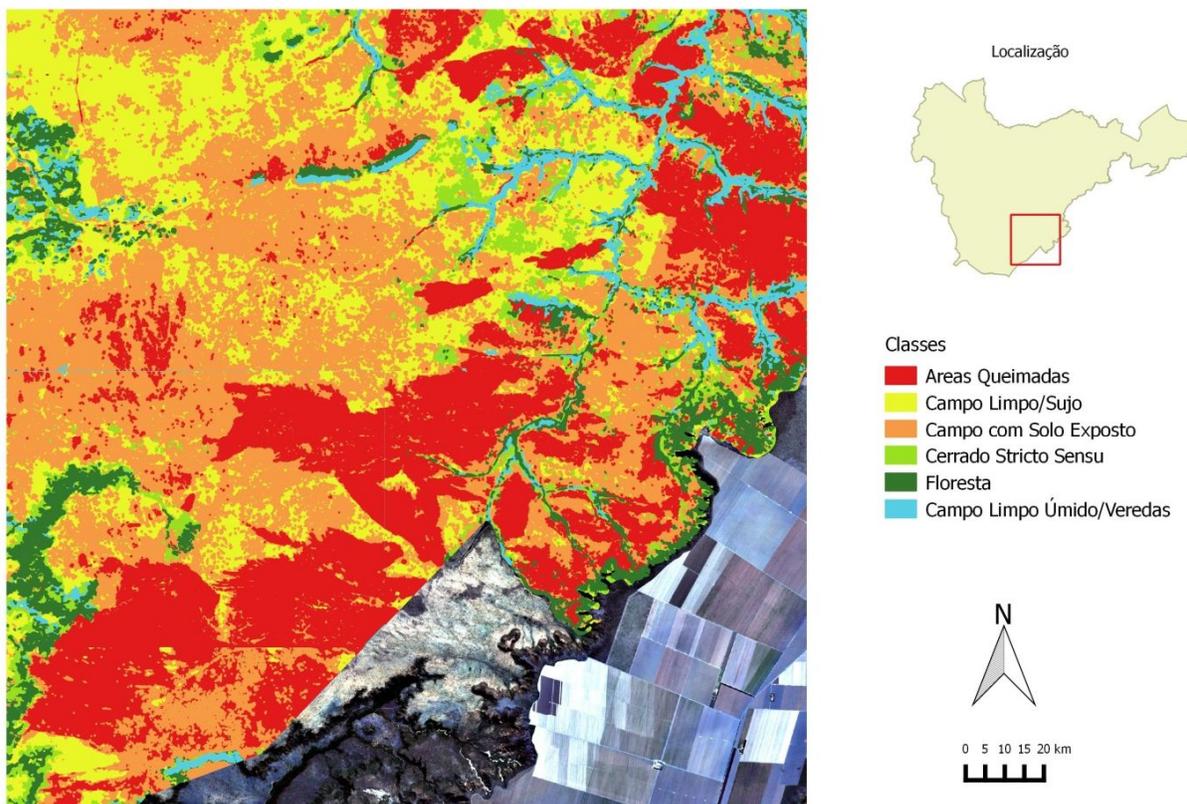


Figura 11: Mapa da Classificação Final Produzida pelo Minerador de Dados J48 na Imagem RapidEye da cena 2333907 de 13/06/2011.

4.2 Resultado da classificação usando árvore de decisão construída pelo usuário

A figura 12 mostra a estrutura da Árvore de Decisão resultante dos testes de parâmetros e limiares atribuído pelo usuário. A Média da banda 3 estabeleceu a primeira distinção entre as Áreas Queimadas e Campo com Solo Exposto das demais classes, considerando um limiar de 960,000.

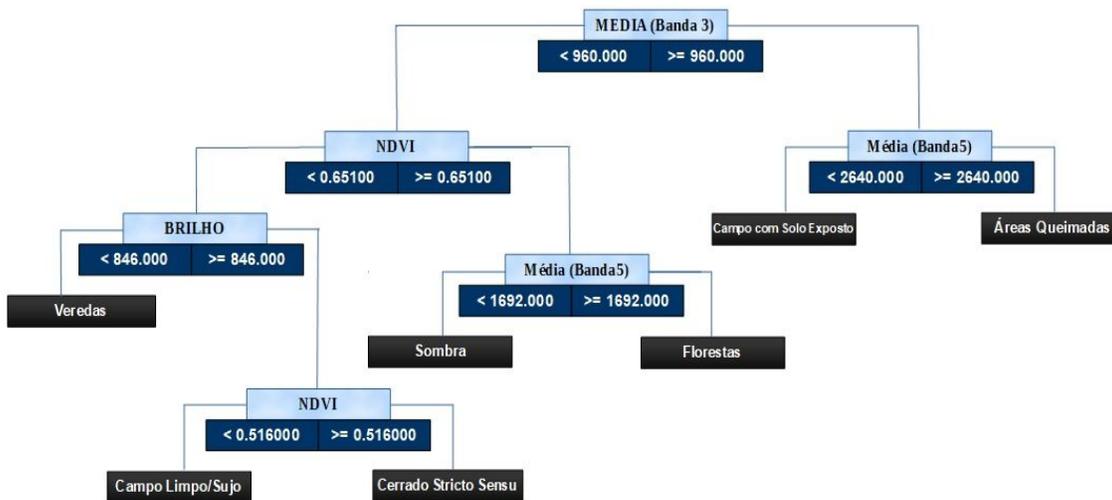


Figura 12: Árvore de Decisão Obtida por Testes de Parâmetros e Limites

A diferenciação entre as Áreas Queimadas e o Campo com Solo Exposto foi determinada pela média da banda 5 com o limiar de 2640,000 (figura 12). Os objetos não selecionados nesta primeira separação (menores que 960,000) são divididos entre os que possuem valores do índice de NDVI superior ou inferior a 0,65100. Os que possuem valores acima desse limiar são classificados na próxima etapa ou como Florestas, se possuírem valores da média da banda 5 acima de 1.692,000, ou como sombra, se seus valores da média da banda 5 são menores que 1.692,000. Os objetos com valores de NDVI abaixo de 0,65100 são pertencentes das classes Campo Limpo Úmido/Veredas, Campo Limpo/Sujo ou Cerrado Stricto Sensu. Para pertencer a classe Campo Limpo Úmido/Veredas, o objeto, além de possuir média da banda 3 abaixo de 960,000, NDVI abaixo de

0,65100, ele também deve ter brilho abaixo de 846,000. Já para o objeto pertencer a classe Campo Limpo/Sujo ou Cerrado Stricto Sensu eles devem satisfazer as condições de apresentarem média da banda 3 abaixo de 960,000, NDVI abaixo de 0,65100, brilho acima de 846,000 e entre eles a diferença se dá pelo limiar do NDVI de 0,51600, em que objetos acima deste valor pertencem a Cerrado Stricto Sensu e abaixo deste valor pertencem a classe Campo Limpo Úmido/Veredas.

Embora a separação das classes Campo Limpo Úmido/Veredas, Campo Limpo/Campo Sujo e Cerrado Stricto Sensu seja parecida com a obtida pelo algoritmo J48, a distinção dessas classes das demais considerou a média da banda 3. Além disso, as classes Campo Limpo/Sujo, Cerrado Stricto Sensu e Floresta podem ser distinguidas por intervalos dentro do índice de NDVI. Isso ocorre porque as fitofisionomias do Cerrado se diferem de acordo com a densidade do estrato arbóreo. Nesse caso, os intervalos se dão da seguinte sequência: Campo Limpo/Sujo $< 0,51600 \geq$ Cerrado Stricto Sensu $< 0,65100 \geq$ Florestas. O teste utilizando o EVI no lugar do NDVI apresenta um resultado parecido na separação dessas classes.

A segmentação utilizou a escala de 100, compactação de 0.5, peso das cores de 0.8 e bandas com o mesmo peso. Todas as classes foram segmentadas com os mesmos valores de segmentação, isto porque o programa não segmenta alguns objetos quando classes diferentes possuem escalas diferentes. A figura 13 mostra o resultado da classificação aplicado sobre uma área amostral da imagem RapidEye cena 2333907 de 13/06/2011 com os testes de parâmetros e limiares.

A figura 14 demonstra o mapa da classificação obtida por Testes de Parâmetros e Limites construído pelo usuário aplicada para toda a cena 2333907 de 13/06/2011 com o recorte do limite da Estação Ecológica Serra Geral do Tocantins. A tabela 3 apresenta a matriz de confusão entre a Imagem Verdade com a Classificação produzida por testes de parâmetros e limiares, respectivamente.

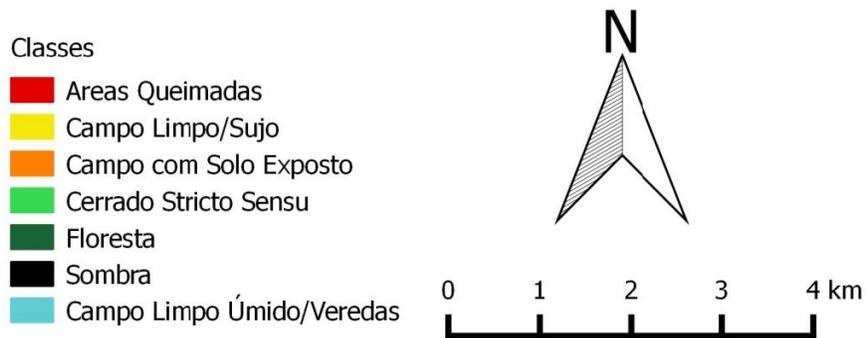
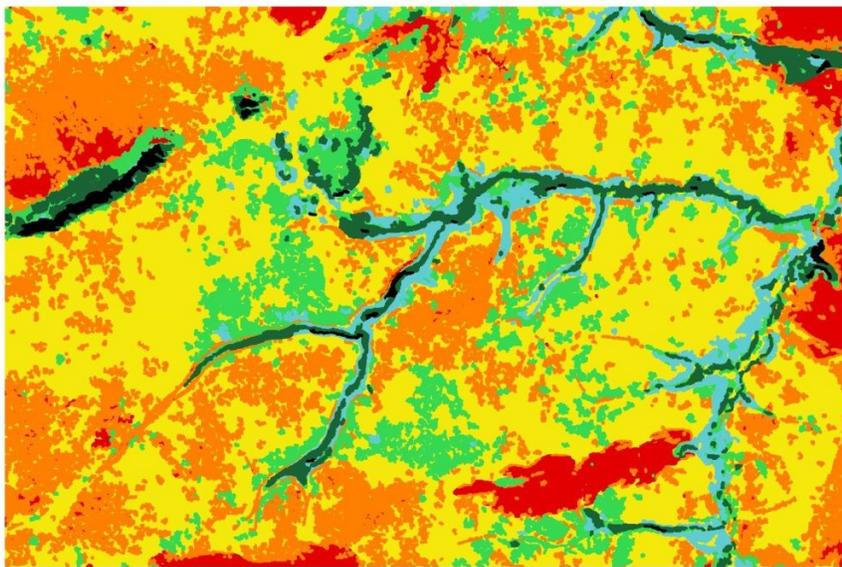
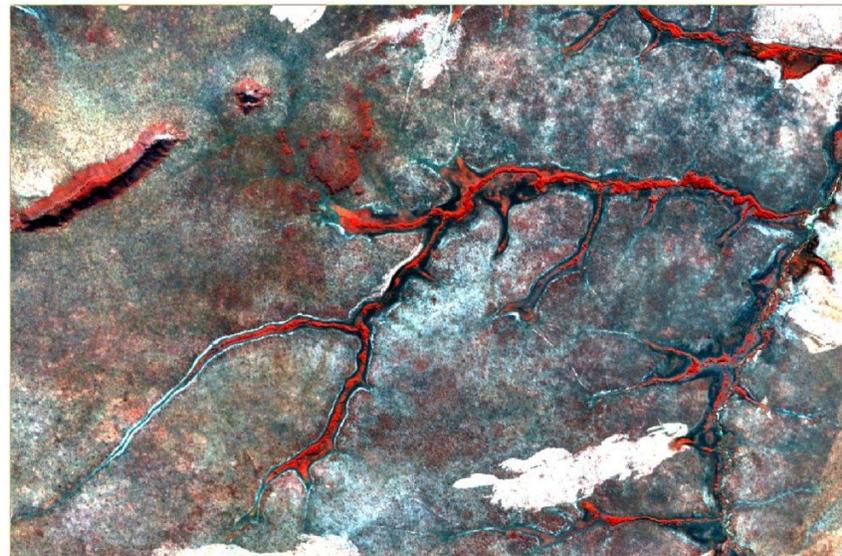


Figura 13: a) Composição colorida RGB (5-2-1) da Imagem RapidEye, b) Classificação da área amostral de acordo com a árvore de decisão produzida pelo usuário através de testes de parâmetros e limiares.

Tabela 3: Matriz de Confusão da Classificação por Testes de Parâmetros e Limiaries

Índice Kappa = 0,783 Acurácia Total = 0,861		Imagem Verdade							Total	Acurácia
		Áreas Queimadas	Campo Limpo/Sujo	Campo Solo Exposto	Cerrado Stricto Senu	Floresta	Veredas	Sombra		
Classificação Por Testes de Parâmetros e Limiaries	Áreas Queimadas	433116	10766	229273	164	0	0	0	673319	64
	Campo Limpo/Sujo	10105	4650851	199048	1209	0	7459	0	4868672	96
	Campo com Solo Exposto	169584	271078	1302074	487	0	0	0	1743223	75
	Cerrado Stricto Senu	0	49329	0	708569	0	30664	0	788562	90
	Floresta	0	604	0	53476	315978	1775	0	371813	85
	Veredas	0	94338	2084	98706	3859	306058	9193	514238	60
	Sombra	0	0	0	0	1193	1012	37968	40173	95
	Total	612805	5076966	1732479	862611	321030	346948	47161	9000000	
	Acurácia	71	92	75	82	98	88	81		86

Como vistos nas tabelas 2 e 3, os resultados mostram uma acurácia total de 81% e 86% para a Classificação com o Minerador e a Classificação por Teste de parâmetros e Limiaries construído pelo usuário, respectivamente. Para o índice Kappa os valores são de 0,704 para a Classificação com o Minerador e 0,783 para a Classificação por Teste de Parâmetros e Limiaries produzidos pelo usuário. Ambas as classificações atingiram resultados substanciais para a acurácia total e para o índice Kappa. Dentre as classes mapeadas, Campo Limpo Úmido/Veredas apresentou o pior aproveitamento de acertos. O problema para esta classe é que há grande diferença de reflectância dos seus alvos pois depende dos gleissolos e da quantidade de Buritis, espécie de palmeiras presente nessa fitofisionomia. Por este motivo, muito dos objetos foram confundidos pelo classificador com objetos de Campo Limpo/Sujo, Cerrado Stricto Senu e Florestas. Ainda, objetos de Campo Limpo Úmido/Veredas com um valor de reflectância muito baixo foram confundidos com objetos de

Sombra. Muitos objetos de Áreas Queimadas foram confundidos com Campo com Solo Exposto pois esta fitofisionomia também apresenta um brilho bem intenso referente ao solo. Quanto aos objetos de Florestas, os maiores erros ocorrem com as classes de Cerrado Stricto Sensu e Campo Limpo Úmido/Veredas.

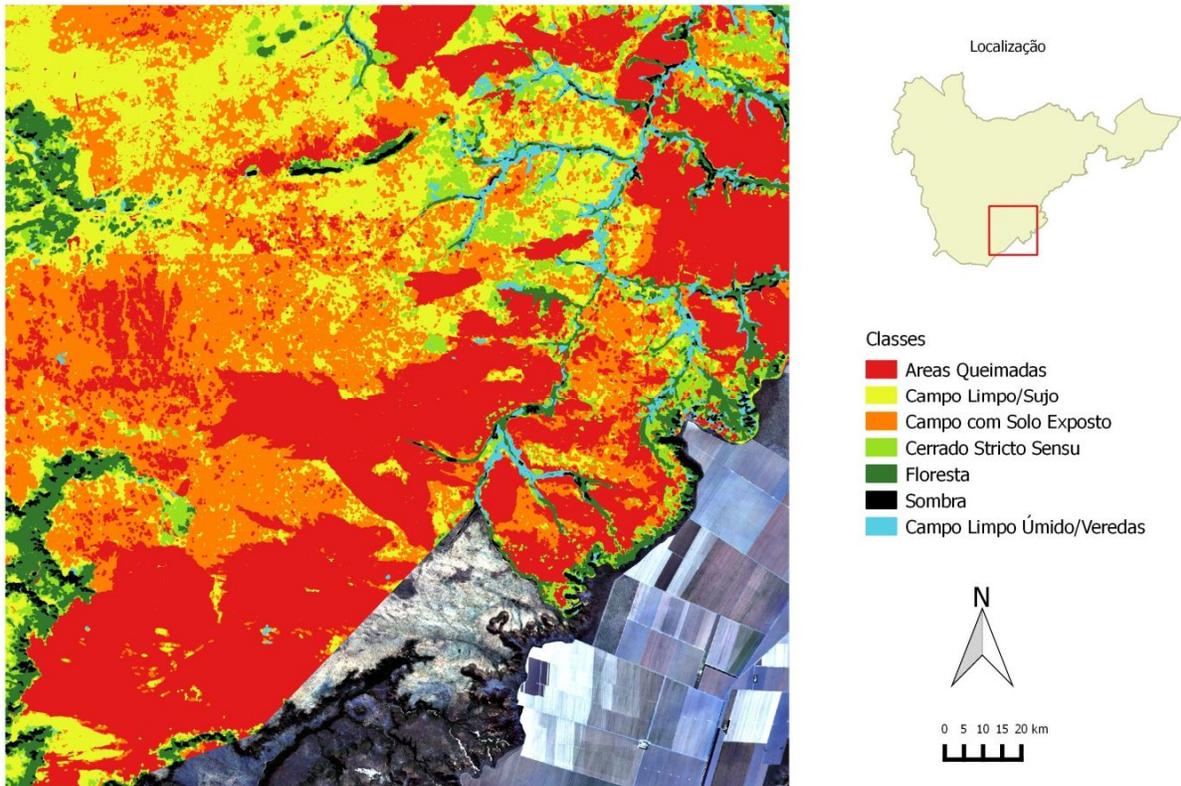


Figura 14: Mapa da classificação produzida pela árvore de decisão elaborada manualmente na imagem RapidEye da cena 2333907 de 13/06/2011.

5. DISCUSSÃO

A classificação por análise orientada-objeto consegue superar alguns problemas encontrados no uso dos métodos baseado em pixels individuais, principalmente em mapeamentos de regiões com heterogeneidade espacial (Pearson, 2002) como os ambientes de savanas (Gibbes et al., 2010). No entanto, esta abordagem possui várias alternativas de mapeamento que pode diminuir ou aumentar os erros. Por exemplo, mudar a escala da segmentação resulta no tamanho do objeto que possui impacto direto nos passos subsequentes da classificação (Myint et al., 2011). O encontro da segmentação com a escala ideal passa por um processo de tentativa e erro baseado na experiência do operador (Stefanski et al., 2013). Os testes realizados demonstraram que a escala de 100 favoreceu distinguir os elementos do Cerrado. Nessa escala, a densidade arbórea pode ser avaliada e não atrapalha o discernimento das classes Floresta e Campo Limpo Úmido/Veredas, enquanto valores superiores a 100 tornam os objetos heterogêneos demais para obter uma classificação precisa dessas classes.

Vários índices foram testados para a distinção das classes, mas os que foram escolhidos são os que obtiveram melhores resultados. Algumas substituições podem ser feitas, tais como utilizar o Brilho para separar as Áreas Queimadas e substituir o NDVI pelo índice de vegetação EVI para classificar as classes Campo Limpo/Sujo, Cerrado Stricto Sensu e Floresta. Ferreira et al. (2008) indica que o NDVI é extremamente útil na estimativa de parâmetros biofísicos da vegetação, mas que existem limitações em áreas de vegetações mais densas. Huete et al. (2002) constataram que o EVI para o mapeamento em vegetações densas é mais adequado que o NDVI, que sofre maior influência no espectro vermelho. Portanto, muitos autores propõem o uso do EVI no estudo de vegetação (Huete et al., 1997). Ginciene et al., (2011) em um mapeando com florestas semi-decidual, comparou os índices de vegetação EVI e NDVI e obteve melhores resultados usando o

EVI. Por estas análises, constata-se que a substituição entre esses dois índices pode ser uma alternativa nesse tipo de mapeamento.

Outras árvores de decisão podem ser estabelecidas, no entanto árvores muito complexas podem não melhorar a acurácia do mapeamento. As tentativas de separação das Formações Florestais de Cerradão e Mata de Galeria/Ciliar não obtiveram êxito, onde nenhum índice apresentou um resultado significativo e, por muitas vezes, criou confusões entre estas duas fitofisionomias. Portanto, a adoção da classe Floresta foi preferida por englobar essas duas fitofisionomias de composição florestal. A classe Cerrado Stricto Sensu (contendo Cerrado Ralo, Cerrado Típico e Cerrado Denso) não foi diferenciada, pois a densidade arbórea é muito sutil e difícil de discernir pela metodologia adotada.

6. CONCLUSÃO

A conservação do bioma Cerrado possui forte pressão exercida pelas fronteiras agrícolas. Neste sentido, o processamento digital de imagens sensoramento remoto permite monitorar as alterações praticadas no meio ambiente. No presente trabalho foi usado uma cena da imagem RapidEye de 5 metros de resolução espacial localizada na parte sul da Estação Ecológica Serra Geral do Tocantins para classificar as fitofisionomias do Cerrado em alto detalhamento espacial. O conhecimento espacial das fitofisionomias do Cerrado é importante para auxiliar no monitoramento, gestão territorial e manejo de incêndios florestais. A classificação detalhada por imagem de alta resolução é primordial pois cada fitofisionomia apresenta um regime diferenciado de queima que reflete na intensidade e expansão do fogo. Normalmente, regiões mais campestres do Cerrado possuem um acúmulo de combustível maior que em cerrados mais florestados. Esta classificação também pode ser usada para um futuro mapeamento das mudanças no uso da terra na região.

No Cerrado, as fitofisionomias são espectralmente similares, mas variam de acordo com a densidade da cobertura arbórea. Uma classificação baseada em objetos é uma metodologia adequada para este tipo de mapeamento, pois lida com áreas e não com o comportamento espectral de pixels individuais. O InterImage, programa especializado na abordagem orientado-objeto permitiu a segmentação da imagem em regiões homogêneas e a classificação por meio de índices e parâmetros estabelecidos pelo método J48 e por testes de limiares e índices aplicados diretamente na imagem pelo usuário. No entanto, existem diferenças entre imagens tanto pela diferença na data de aquisição como pelas peculiaridades do solo e vegetação de cada região. Por isso, os limiares dos parâmetros devem ser ajustados de acordo com a imagem aplicada. As duas classificações obtiveram resultados favoráveis na análise de acurácia. Foram registrados valores de 0,81 nos cálculos de acurácia total e de 0,704 para o índice Kappa na classificação produzida pelo minerador e de 0,86 de acurácia total e 0,783 de índice Kappa na classificação por meio de testes de parâmetros e limiares.

Por conseguinte, a abordagem orientada-objeto se apresentou bastante satisfatória para a classificação das fitofisionomias do Cerrado, pois trata a imagem em segmentos que permite estimar a densidade de indivíduos arbóreos dentro de uma certa área. Vários índices e parâmetros foram testados na classificação. As seguintes distinções não foram possíveis de serem obtidas: (a) Cerrado Ralo de Cerrado Típico e Cerrado Denso; (b) Campo Limpo de Campo Sujo; e (c) Mata de Galeria de Mata Ciliar e essas duas últimas de Cerradão. Para a classe Campo Limpo Úmido/Veredas, por apresentar uma variação grande do comportamento de reflectância de seus alvos, foi escolhido não superestimar tanto a sua classificação pois a confusão com classes como Cerrado Stricto Sensu e Campo Limpo/Sujo torna o mapeamento menos acurado.

REFERÊNCIAS BIBLIOGRÁFICAS

ADAMCZYK, J.; OSBERGER, A. Red-edge vegetation indices for detecting and assessing disturbances in Norway spruce dominated mountain forests. **International Journal of Applied Earth Observation and Geoinformation**, v. 37, p. 90-99, 2015.

ADDINK, E.A.; DE JONG, S. M.; PEBESMA, E. J. The importance of scale in object-based mapping of vegetation parameters with hyperspectral imagery. **Photogrammetric Engineering & Remote Sensing**, v. 73, n. 8, p. 905-912, 2007.

ADDINK, E.A.; VAN COILLIE, F. M. B.; DE JONG, S. M. Introduction to the GEOBIA 2010 special issue: From pixels to geographic objects in remote sensing image analysis. **International Journal of Applied Earth Observation and Geoinformation**, v.15, p.1-6, 2012.

ANDERSON, C.; THIELE, M.; BRUNN, A. Calibration and validation of the RapidEye constellation. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16., 2013, Foz do Iguaçu, PR. **Anais...** São José dos Campos: INPE, 2013. p. 9143-9150.

BAATZ, M., SCHÄPE, A. Multiresolution segmentation—an optimization approach for high quality multi-scale image segmentation. In: Strobl, J., Blaschke, T., Griesebner, G. (Eds.), **Angewandte Geographische Informations-Verarbeitung XII**. Karlsruhe: Wichmann Verlag, 2000. p. 12 – 23.

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

BLASCHKE, T.; HAY, G.J.; KELLY, M.; LANG, S.; HOFMANN, P.; ADDINK, E.; FEITOSA, R.Q.; VAN DER MEER, F.; VAN DER WERFF, H.; VAN COILLIE, F.; TIEDE, D. Geographic object-based image analysis—towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 180-191, 2014.

BRASIL. Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio). **Plano de Manejo Estação Ecológica Serra Geral do Tocantins**. Brasília: ICMBIO, 2014. 575 p.

BRASIL. **Decreto de 27 de setembro de 2001**. Cria a Estação Ecológica Serra Geral do Tocantins, nos Estados do Tocantins e da Bahia, e dá outras providências. Disponível em <http://www.planalto.gov.br/ccivil_03/DNN/2001/Dnn9340.htm>. Acesso em 13 março 2016.

BRASIL. Ministério do Meio Ambiente. **Mapeamento do Uso e Cobertura do Cerrado: Projeto TerraClass Cerrado 2013**. Brasília, DF: MMA, 2015.

BRENNER, V. C.; GUASSELLI, L. A. Índice de diferença normalizada da água (NDWI) para identificação de meandros ativos no leito do canal do rio Gravataí/RS–Brasil. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa, PB. **Anais...** São José dos Campos: INPE, 2015. p. 3693-3699.

CARLEER, A.P.; DEBEIR, O.; WOLFF, E. Exploitation of very high-resolution satellite data for tree species identification. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 1, p. 135-140, 2004.

CHEN, G.; HAY, G. J.; ST-ONGE, B. A GEOBIA framework to estimate forest parameters from lidar transects, Quickbird imagery and machine learning: A case study in Quebec, Canada. **International Journal of Applied Earth Observation and Geoinformation**, v. 15, p. 28-37, 2012.

COLE, M. M. **The savannas, biogeography and geobotany**. London, UK: Academic Press, 1986.

CONGALTON, R.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Boca Raton, FL: CRC Press, 2008.

CARVALHO, A.A.A.A. de; GREGÓRIO, L. da S.; FERREIRA, M.R.F.; COUTO, R. de S.; CASTRO, W.O. de; ALVES, W.F.; COSTA, G.O.A.P.; BRITES, R.S.; BIAS, E. de S. Análise de classificação de imagem Rapideye por meio dos softwares Interimage e Spring. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 26., 2014, Gramado, RS. **Anais...** Rio de Janeiro: Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto, 2014.

CARVALHO JÚNIOR, O.A.; GUIMARÃES, R.F.; SILVA, C.R.; GOMES, R.A.T. Standardized Time-Series and Interannual Phenological Deviation: New Techniques for Burned-Area Detection Using Long-Term MODIS-NBR Dataset. **Remote Sensing**, v. 7, p. 6950-6985, 2015

COSTA, G. A.; CAZES, G.B. Aplicação de Algoritmos Genéticos para a Evolução de Parâmetros para a Segmentação de Imagens. Disponível em: <http://rica.ele.puc-rio.br/media/Revista_rica_n6_a3.pdf>. Acesso em 18 de julho de 2017.

DALDEGAN, G. A.; DE CARVALHO, O. A.; GUIMARÃES, R. F.; GOMES, R. A. T.; RIBEIRO, F. D. F.; MCMANUS, C. Spatial patterns of fire recurrence using remote sensing and GIS in the Brazilian savanna: Serra do Tombador Nature Reserve, Brazil. **Remote Sensing**, v. 6, n. 10, p. 9873-9894, 2014.

DE SOUZA, C. H. R.; SOUZA, C.G.; ZANELLA, L.; CARVALHO, L. M. T. Analysis of Rapideye's Red edge band for image segmentation and classification. In: INTERNATIONAL

CONFERENCE ON GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS (GEOBIA), 4., Rio de Janeiro, RJ. **Proceedings ...**, São José dos Campos: INPE, v. 79, p. 518, 2012.

DEZSÖ, B.; FEKETE, I.; GERA, D.; GIACHETTA, R.; LÁSZLÓ, I. Object-Based Image Analysis in Remote Sensing Applications Using Various Segmentation Techniques. **Annales Universitatis Scientiarum Budapestinensis de Rolando Eotvos Nominatae Sectio Computatorica**. v. 37, p. 103-120, 2012.

DUPUY, S.; BARBE, E.; BALESTRAT, M. An object-based image analysis method for monitoring land conversion by artificial sprawl use of RapidEye and IRS data. **Remote Sensing**, v. 4, n. 2, p. 404-423, 2012.

EHLERS, M.; GAHLER, M.; JANOWSKY, R. Automated analysis of ultra-high resolution remote sensing data for biotope type mapping: new possibilities and challenges. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 57, n. 5, p. 315-326, 2003.

ELATAWNEH, A.; WALLNER, A.; MANAKOS, I.; SCHNEIDER, T.; KNOKE, T. Forest cover database updates using multi-seasonal RapidEye data—Storm event assessment in the Bavarian forest national park. **Forests**, v. 5, n. 6, p. 1284-1303, 2014.

FERREIRA, L. G.; FERREIRA, N. C.; FERREIRA, M. E. Sensoriamento remoto da vegetação: evolução e estado-da-arte. **Acta Scientiarum. Biological Sciences**, v. 30, n. 4, 2008.

FOODY, G.M. Thematic mapping from remotely sensed data with neural networks: MLP, RBF and PNN based approaches. **Journal of Geographical Systems**, v. 3, n. 3, p. 217-232, 2001.

FOODY, G. M. Thematic map comparison. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 5, p. 627-633, 2004.

FRIEDL, M. A.; BRODLEY, C. E. Decision tree classification of land cover from remotely sensed data. **Remote sensing of environment**, v. 61, n. 3, p. 399-409, 1997.

FRIEDL, M. A.; BRODLEY, C.E.; STRALHER, A. H. Maximizing land cover classification accuracies produced by decision trees at continental to global scales. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 2, p. 969-977, 1999.

GAO, B. C. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257-266, 1996.

GIBBES, C.; ADHIKARI, S.; ROSTANT, L.; SOUTHWORTH, J.; QIU, Y. Application of object based classification and high resolution satellite imagery for savanna ecosystem analysis. **Remote Sensing**, v. 2, n. 12, p. 2748-2772, 2010.

GIBBONS, P.; ZERGER, A.; JONES, S.; RYAN, P. Mapping vegetation condition in the context of biodiversity conservation. **Ecological Management & Restoration**, v. 7, n. s1, 2006. doi: 10.1111/j1442-8903.2006.00282.x

GINCIENE, B. R.; BITENCOURT, M. D. Utilização do EVI (Enhanced Vegetation Index) para maior sensibilidade na detecção de mudanças temporais em fragmentos de floresta estacional semidecidual. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba, PR. **Anais...** São José dos Campos: INPE, 2011. p.1620-1627.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA data mining software: an update. **ACM SIGKDD Explorations Newsletter**, v. 11, n. 1, p. 10-18, 2009.

HARBEY, K. R.; HILL, G. J. E. Vegetation mapping of a tropical freshwater swamp in the Northern Territory, Australia: a comparison of aerial photography, Landsat TM and SPOT satellite imagery. **International Journal of Remote Sensing**, v. 22, n. 15, p. 2911-2925, 2001.

HOU, W.; WALZ, U. Extraction of small biotopes and ecotones from multi-temporal RapidEye data and a high-resolution normalized digital surface model. **International Journal of Remote Sensing**, v. 35, n. 20, p. 7245-7262, 2014.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; VAN LEEUWEN, W. J. D. A. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440-451, 1997.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, n. 1, p. 195-213, 2002.

IBGE, Mapa de Biomas e de Vegetação, 2004. Disponível em: <<http://www.ibge.gov.br/home/presidencia/noticias/20152004biomashtml.shtm>>. Acesso em: 15 abril 2016.

INTERIMAGE, InterImage 1.30 Manual do Usuário. Disponível em: www.lvc.ele.puc-rio.br/projects/interimage/pt-br. Acesso em: 11 de Dezembro de 2016.

JOBIN, B.; LABRECQUE, S.; GRENIER, M.; FALARDEAU, G. Object-based classification as an alternative approach to the traditional pixel-based classification to identify potential habitat of the Grasshopper Sparrow. **Environmental Management**, v. 41, n. 1, p. 20-31, 2008.

KRISCHKE, M.; NIEMEYER, W.; SCHERER, S. RapidEye satellite based geo-information system. **Acta Astronautica**, v. 46, n. 2, p. 307-312, 2000.

LANDIS, J. R.; KOCH, G. G. The Measurement of observer agreement for categorical data. **Biometrics**, p. 159-174, 1977.

LATORRE, M. L.; CARVALHO JÚNIOR, O. A.; SANTOS, J. R. D.; SHIMABUKURO, Y. E. Integração de dados de sensoriamento remoto multi resoluções para a representação da cobertura da terra utilizando campos contínuos de vegetação e classificação por árvores de decisão. **Revista Brasileira de Geofísica**, v. 25, n. 1, p. 63-74, 2007.

MA, L.; CHENG, L.; LI, M.; LIU, Y.; MA, X. Training set size, scale, and features in Geographic Object-Based Image Analysis of very high resolution unmanned aerial vehicle imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 14-27, 2015.

MORA, B.; WULDER, M. A.; WHITE, J. C. Segment-constrained regression tree estimation of forest stand height from very high spatial resolution panchromatic imagery over a boreal environment. **Remote Sensing of Environment**, v. 114, n. 11, p. 2474-2484, 2010.

MYERS, N.; MITTERMEIER, R. A.; MITTERMEIER, C. G.; FONSECA, G.A.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, n. 6772, p. 853, 2000.

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

PEARSON, D. M. The application of local measures of spatial autocorrelation for describing pattern in north Australian landscapes. **Journal of Environmental Management**, v. 64, n. 1, p. 85-95, 2002.

QUINLAN, J. R. **C4. 5: programs for machine learning**. San Mateo, CA: Morgan Kaufmann Publisher, 2014. 302 p.

QUINLAN, J. R. Improved use of continuous attributes in C4. 5. **Journal of Artificial Intelligence Research**, v. 4, p. 77-90, 1996.

RAPINEL, S.; CLÉMENT, B.; MAGNANON, S.; SELLIN, V.; HUBERT-MOY, L. Identification and mapping of natural vegetation on a coastal site using a Worldview-2 satellite image. **Journal of Environmental Management**, v. 144, p. 236-246, 2014.

RAMOELO, A. Regional estimation of savanna grass nitrogen using the red-edge band of the spaceborne RapidEye sensor. **International Journal of Applied Earth Observation and Geoinformation**, v. 19, p. 151-162, 2012.

RAPIDEYE. RapidEye AG Satellite Image Product Specifications, 2007. Disponível em <http://www.gisat.cz/images/upload/c1626_rapideye-image-product-specs-april-07.pdf> Acesso em 18 de Maio 2016.

RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do bioma cerrado in: Sano, SM; Almeida, SP; Ribeiro, JF Cerrado: Ecologia e Flora. **Brasília: Embrapa Informação Tecnológica**, 2008.

RICHTER, R. Correction of atmospheric and topographic effects for high spatial resolution satellite imagery. **International Journal of Remote Sensing**, v. 18, n. 5, p. 1099-1111, 1997.

RITTL, T.; COOPER, M.; HECK, R. J.; BALLESTER, M. V. R. Object-based method outperforms per-pixel method for land cover classification in a protected area of the Brazilian Atlantic rainforest region. **Pedosphere**, v. 23, n. 3, p. 290-297, 2013.

ROUSE, J. W.; HASS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN, J. C. **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. Final Report, RSC 1978-4, Texas A & M University, College Station, Texas, 1974. 9 p.

SEPLAN, Superintendência de Pesquisa e Zoneamento Ecológico-Econômico – Diretoria de Zoneamento Ecológico-Econômico. Projeto de Desenvolvimento Regional Sustentável. **Mapeamento das regiões fitoecológicas e inventário florestal do estado do Tocantins**. Palmas, TO: SEPLAN, 2013. 135 p.

SEPLAN, Superintendência de Pesquisa e Zoneamento Ecológico-Econômico – Diretoria de Zoneamento Ecológico-Econômico. Projeto de Desenvolvimento Regional Sustentável. **Mapeamento das regiões fitoecológicas e inventário florestal do estado do Tocantins. Inventário Florestal da Faixa Centro**. Palmas, TO: SEPLAN, 2013. 354p.

STEFANSKI, J.; MACK, B.; WASKE, B. O. R. Optimization of object-based image analysis with random forests for land cover mapping. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 6, n. 6, p. 2492-2504, 2013.

STOLL, E.; MERZ, K.; KRAG, H.; D'SOUZA, B.; BASTIDA, V. B. Collision Probability Assessment for the Rapideye Satellite Constellation. In: EUROPEAN CONFERENCE ON SPACE DEBRIS, 6., 2013. Darmstadt. **Proceedings...** Darmstadt: European Space Agency (ESA), v. 723

TRODD, N. M. Uncertainty in land cover mapping for modelling land cover change. In: ANNUAL CONFERENCE OF THE REMOTE SENSING SOCIETY, RSS95: Remote Sensing in Action, 21., 1995, Southampton. **Proceedings...** Nottingham: Remote Sensing Society, 1995. p. 1138 – 1145.

VILLELA, F. N. J.; NOGUEIRA, C. Geologia e geomorfologia da estação ecológica Serra Geral do Tocantins. **Biota Neotropica**, v. 11, n. 1, 2011.

XIE, Y.; SHA, Z.; YU, M. Remote sensing imagery in vegetation mapping: a review. **Journal of Plant Ecology**, v. 1, n. 1, p. 9-23, 2008.

WHITESIDE, T. G.; BOGGS, G. S.; MAIER, S. W. Comparing object-based and pixel-based classifications for mapping savannas. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, n. 6, p. 884-893, 2011.

WITHARANA, C.; CIVCO, D. L. Optimizing multi-resolution segmentation scale using empirical methods: Exploring the sensitivity of the supervised discrepancy measure Euclidean distance 2 (ED2). **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 87, p. 108-121, 2014.

ZHAO, Y.; ZHANG, Y. Comparison of decision tree methods for finding active objects. **Advances in Space Research**, v. 41, n. 12, p. 1955-1959, 2008.