

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**DETECÇÃO AUTOMÁTICA DE VOÇOROCAS A PARTIR DA
ANÁLISE DE IMAGENS BASEADA EM OBJETOS
GEOGRÁFICOS - GEOBIA**

Alex Garcez Utsumi

Engenheiro Ambiental

2019

UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

**DETECÇÃO AUTOMÁTICA DE VOÇOROCAS A PARTIR DA
ANÁLISE DE IMAGENS BASEADA EM OBJETOS
GEOGRÁFICOS - GEOBIA**

Discente: Alex Garcez Utsumi

Orientadora: Profa. Dra. Teresa Cristina Tarlé Pissarra

Coorientador: Prof. Dr. David Luciano Rosalen

**Tese apresentada à Faculdade de Ciências
Agrárias e Veterinárias - Unesp, Câmpus de
Jaboticabal, como parte das exigências para
obtenção do título de Doutor em Agronomia
(Ciência do Solo).**

2019

U92d

Utsumi, Alex Garcez

Detecção automática de voçorocas a partir da Análise de Imagens Baseada em Objetos Geográficos - GEOBIA / Alex Garcez Utsumi. -- Jaboticabal, 2019

84 p. : tabs., fotos, mapas

Tese (doutorado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientadora: Teresa Cristina Tarlé Pissarra

Coorientador: David Luciano Rosalen

1. Geociências. 2. Sensoriamento remoto. 3. Solos Erosão. I.
Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

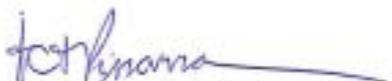
TÍTULO DA TESE: DETECÇÃO AUTOMÁTICA DE VOÇOROCAS A PARTIR DA ANÁLISE DE IMAGENS BASEADA EM OBJETOS GEOGRÁFICOS - GEOBIA

AUTOR: ALEX GARCEZ UTSUMI

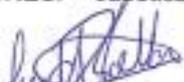
ORIENTADORA: TERESA CRISTINA TARLE PISSARRA

COORIENTADOR: DAVID LUCIANO ROSALEN

Aprovado como parte das exigências para obtenção do Título de Doutor em AGRONOMIA (CIÊNCIA DO SOLO), pela Comissão Examinadora:



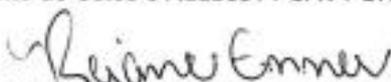
Prof.^a Dr.^a TERESA CRISTINA TARLE PISSARRA
Engenharia Rural / FCAV / UNESP - Jaboticabal



Pós-doutorando LUIZ HENRIQUE DA SILVA ROTTA
Departamento de Cartografia FCT/UNESP / Presidente Prudente/SP



Prof. Dr. MARCÍLIO VIEIRA MARTINS FILHO
Departamento de Solos e Adubos / FCAV / UNESP - Jaboticabal



Profa. Dra. REJANE ENNES CICERELLI
Instituto de Geociências-UnB / Brasília/DF



Prof. Dr. NEWTON LA SCALA JUNIOR
Departamento de Ciências Exatas / FCAV / UNESP - Jaboticabal

Jaboticabal, 16 de maio de 2019

DADOS CURRICULARES DO AUTOR

Alex Garcez Utsumi, nascido em 23 de abril de 1986 em Alexânia, GO, é Engenheiro Ambiental pela Universidade Estadual Paulista (2008), Câmpus de Presidente Prudente. Em 2010 ingressou no curso de mestrado, no programa de Pós-Graduação em Ciências Cartográficas, na Faculdade de Ciências e Tecnologia da Universidade Estadual Paulista, Câmpus de Presidente Prudente. Em 2013 tornou-se Professor Assistente da Universidade Federal do Triângulo Mineiro – UFTM – atuando no Departamento de Engenharia Ambiental, onde trabalha na área de Sensoriamento Remoto e Geoprocessamento. Em 2016 ingressou no curso de doutorado no programa de Pós-Graduação em Agronomia, área de concentração Ciência do Solo, da Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista, Câmpus de Jaboticabal.

AGRADECIMENTOS

À minha orientadora, professora Dra. Teresa Cristina Tarlé Pissarra, pela oportunidade, pelo empenho, pela confiança e pela divisão de conhecimentos.

Ao meu co-orientor, professor Dr. David Luciano Rosalen, pela paciência, dedicação e ensinamentos transmitidos.

Aos professores do Curso de Pós-Graduação em Agronomia da Universidade Estadual Paulista - UNESP, pela dedicação e ensinamentos.

Aos colegas do programa de Pós-Graduação, pelos conselhos e auxílio em diversos momentos do doutorado.

À minha companheira, Nádia Guimarães Sousa, pelo amor, conselhos, paciência e motivação.

À minha família, que sempre me deu suporte para a minha formação.

Ao Departamento de Engenharia Ambiental da Universidade Federal do Triângulo Mineiro - UFTM, pelo apoio e concessão da licença para a realização do doutorado.

À todas as pessoas que de alguma forma contribuíram para a realização dessa tese.

SUMÁRIO

LISTA DE TABELAS	v
LISTA DE FIGURAS	vi
1 INTRODUÇÃO	1
2 OBJETIVOS	4
2.1 Objetivos específicos	4
3 REVISÃO DA LITERATURA	5
3.1 Erosão dos solos	5
3.1.1 Voçorocas	7
3.2 Análise de Imagens Baseada em Objetos Geográficos	11
3.2.1 Criação da rede semântica	12
3.2.2 Segmentação	13
3.2.3 Criação das regras para separação das classes	18
3.2.4 Avaliação da acurácia.....	21
4 MATERIAL E MÉTODOS	25
4.1 Área de estudo.....	25
4.2 Material.....	26
4.3 Métodos	27
4.3.1 Pré-processamento dos dados	28
4.3.2 Definição das classes de uso e cobertura do solo	29
4.3.3 Classificação a partir do modelo empírico.....	29
4.3.4 Classificação por árvore de decisão.....	38
4.3.5 Avaliação da acurácia.....	41
5 RESULTADOS E DISCUSSÃO	43
5.1 Área de estudo 1	43
5.1.1 Classificação das voçorocas a partir do modelo óptico.....	43
5.1.2 Classificação das voçorocas a partir do modelo combinado.....	46
5.1.3 Classificação das voçorocas por árvore de decisão.....	48
5.1.4 Avaliação da acurácia.....	50
5.2 Área de estudo 2.....	55
5.2.1 Classificação das voçorocas a partir do modelo óptico.....	55

5.2.2 Classificação das voçorocas a partir do modelo combinado.....	59
5.2.3 Classificação por árvore de decisão.....	63
5.2.4 Avaliação da acurácia	67
6 CONCLUSÕES	71
7 REFERÊNCIAS.....	72
8 CONSIDERAÇÕES FINAIS.....	83

DETECÇÃO AUTOMÁTICA DE VOÇOROCAS A PARTIR DA ANÁLISE DE IMAGENS BASEADA EM OBJETOS GEOGRÁFICOS - GEOBIA

RESUMO – A voçoroca é o estágio mais avançado da erosão hídrica, causando inúmeros prejuízos para o meio ambiente e para o homem. Devido à extensão desse fenômeno e a dificuldade de acesso em campo, as técnicas de detecção automática de voçorocas têm despertado interesse, especialmente por meio da Análise de Imagens Baseada em Objetos Geográficos (GEOBIA). O objetivo desse trabalho foi mapear voçorocas utilizando a GEOBIA a partir de imagens RapidEye e dados SRTM, em duas regiões localizadas em Uberaba, Minas Gerais. Para isso, foi proposto aplicar o Índice de Avaliação da Segmentação (SEI) na etapa de segmentação da imagem. A criação das regras para detecção das voçorocas foi realizada de forma empírica, no *software* InterIMAGE, e de forma automática, a partir do algoritmo de árvore de decisão. A avaliação da acurácia foi realizada por meio dos coeficientes de concordância extraídos da matriz de confusão e, adicionalmente, a partir da sobreposição com dados de referência vetorizados manualmente. O índice SEI proporcionou a criação de objetos semelhantes às voçorocas, permitindo a extração de atributos específicos desses alvos. As regras de classificação do modelo empírico permitem detectar voçorocas nas duas áreas de estudos, ainda que essas feições ocupem uma pequena porção da cena. Os modelos empíricos alcançaram resultados satisfatórios: índice Kappa de 0,74 e F-measure de 53,46% na área 1, e índice Kappa de 0,73 e F-measure de 55,95% na área 2. A informação altimétrica mostrou ser um importante parâmetro para a detecção das voçorocas, de modo que ao retirar a declividade dos modelos empíricos houve redução do índice F-measure em 34,90% na área 1 e 28,65% na área 2. Os modelos gerados pelos algoritmos de árvore de decisão apresentaram desempenho inferior em função do número de voçorocas disponíveis para o treinamento do algoritmo e da impossibilidade de criar uma segmentação específica para cada classe de uso e cobertura do solo.

Palavras-chave: avaliação da segmentação, árvore de decisão, erosão, sensoriamento remoto.

AUTOMATIC GULLY DETECTION FROM GEOGRAPHIC OBJECT BASED IMAGE ANALYSIS - GEOBIA

ABSTRACT - Gully is the most advanced stage of water erosion, causing numerous damages to the environment and man. Due to the extension of this phenomenon and the difficulty of access in the field, automatic gully detection techniques have aroused interest, especially through Geographic Object Based Image Analysis (GEOBIA). The objective of this work was to map gullies using GEOBIA from RapidEye images and SRTM data, in two regions located in Uberaba, Minas Gerais. It was proposed to apply the Segmentation Evaluation Index (SEI) in the image segmentation stage. The rule set creation for gully detection was made empirically in the InterIMAGE software, and automatically, from the decision tree algorithm. The accuracy assessment was performed based on concordance coefficients extracted from the confusion matrix and, additionally, overlapping manually digitized reference data. The SEI index allowed the creation of objects similar to real gullies, providing the extraction of specific attributes of these targets. Empirical model rule set allowed gully detection on both study areas, although these features occupied a small portion of the scene. Empirical models have achieved very good results: Kappa index of 0.74 and F-measure of 53.46% in area 1, and Kappa index of 0.73 and F-measure of 55.95% in area 2. Altimetric information proved to be an important parameter for gully detection, since slope removal from the empirical models reduced the F-measure index by 34,90% in area 1 and 28,65% in area 2. The rule set generated by decision tree presented lower performance due to the number of gullies available for algorithm training and the impossibility of creating a specific segmentation for each land use/cover class.

Keywords: segmentation evaluation, decision tree, erosion, remote sensing.

LISTA DE TABELAS

Tabela 1. Classificação do índice Kappa.	23
Tabela 2. Otimização da segmentação das voçorocas na área de estudo 1.	33
Tabela 3. Parâmetros de segmentação para o pasto, sombra, vegetação arbórea e solo exposto.	35
Tabela 4. Descrição dos parâmetros do modelo empírico para detectar voçorocas	36
Tabela 5. Parâmetros utilizados para detectar as voçorocas no modelo empírico. ..	37
Tabela 6. Descrição dos parâmetros do modelo empírico para as demais classes..	37
Tabela 7. Regras do modelo empírico para as demais classes.	38
Tabela 8. Descrição dos parâmetros gerados pela árvore de decisão.	41
Tabela 9. Matriz de confusão criada a partir do modelo óptico na área 1.	51
Tabela 10. Matriz de confusão criada a partir do modelo combinado na área 1.	52
Tabela 11. Matriz de confusão criada a partir do algoritmo de árvore de decisão na área 1.	53
Tabela 12. Avaliação da acurácia a partir da sobreposição com os dados vetorizados na área 1.	54
Tabela 13. Matriz de confusão criada a partir do modelo óptico na área 2.	67
Tabela 14. Matriz de confusão criada a partir do modelo combinado na área 2.	68
Tabela 15. Matriz de confusão criada a partir da árvore de decisão na área 2.	69
Tabela 16. Resultados da acurácia global e do índice Kappa nas duas áreas.	69
Tabela 17. Avaliação da acurácia a partir da sobreposição com os dados vetorizados na área 2.	70

LISTA DE FIGURAS

Figura 1. Caracterização das formas do relevo.....	8
Figura 2. Estrutura da matriz de confusão.....	22
Figura 3. Localização das áreas de estudo: a) área 1 e b) área 2.....	25
Figura 4. Fluxograma dos procedimentos metodológicos.	27
Figura 5. Processo de classificação no <i>software</i> InterIMAGE..	30
Figura 6. Redes semânticas para a área de estudo 1: A (modelo óptico) e B (modelo combinado).....	31
Figura 7. Redes semânticas para a área de estudo 2: A (modelo óptico) e B (modelo combinado).....	32
Figura 8. Modelo gerado pelo algoritmo de árvore de decisão para a área 1.	39
Figura 9. Modelo gerado pelo algoritmo de árvore de decisão para a área 2.	40
Figura 10. Classificação do uso e cobertura do solo a partir do modelo óptico na área 1.	43
Figura 11. Detalhamento da classificação das voçorocas a partir do modelo óptico na área 1.	44
Figura 12. Imagem de uma voçoroca pequena na área 1.	45
Figura 13. Classificação do uso e cobertura do solo a partir do modelo combinado na área 1.	47
Figura 14. Detalhamento da classificação das voçorocas a partir do modelo combinado na área 1.....	48
Figura 15. Classificação do uso e cobertura do solo a partir da árvore de decisão na área 1.	49
Figura 16. Detalhamento da classificação das voçorocas a partir do algoritmo de árvore de decisão na área 1.....	50
Figura 17. Classificação do uso e cobertura do solo a partir do modelo óptico na área 2.	56
Figura 18. Imagem da voçoroca de maior extensão na área de estudo 2.....	57
Figura 19. Detalhamento da classificação das voçorocas a partir do modelo óptico na área 2.	58
Figura 20. Classificação do uso e cobertura do solo a partir do modelo combinado na área 2.	60
Figura 21. Detalhamento da classificação das voçorocas a partir do modelo combinado na área 2.....	62
Figura 22. Classificação do uso e cobertura do solo a partir da árvore de decisão na área 2.	64
Figura 23. Detalhamento da classificação das voçorocas a partir do algoritmo de árvore de decisão na área 2.....	66

1 INTRODUÇÃO

A erosão hídrica é reconhecida como uma das principais causas da degradação da terra no planeta, estimando-se que cerca de 10 milhões de hectares de solos férteis são perdidos por ano (Luffman et al., 2015). O manejo inadequado de pastagens e de cultivos agrícolas tem potencializado esse fenômeno, intensificando a degradação do solo e dos corpos d'água em níveis alarmantes.

O estágio mais avançado da erosão hídrica culmina no surgimento das voçorocas, as quais podem ser formadas por erosão superficial, erosão subsuperficial e movimentos de massa (Bacellar, 2006; Zhang et al., 2015). Essas feições erosivas são consideradas indicadores de severa degradação do solo, podendo causar a redução da área utilizável no campo, assoreamento dos rios e risco de acidentes.

Assim como outros perigos naturais, como movimentos de terra, terremotos e enchentes, geralmente não é fácil prever o aparecimento das voçorocas. Por esse motivo, uma vez estabelecidas, elas devem ser mapeadas e monitoradas, pois possuem consequências nocivas para o ambiente e para o homem (Shit et al., 2015). A partir do mapeamento das voçorocas é possível planejar ações corretivas, bem como aumentar a compreensão da dinâmica de produção de sedimentos ao longo do tempo.

O Sensoriamento Remoto e os Sistemas de Informações Geográficas são utilizados com frequência na fotointerpretação visual da erosão, bem como em estudos qualitativos sobre a vulnerabilidade aos processos erosivos e em estudos quantitativos, baseados na Equação Universal de Perda de Solos. No entanto, as pesquisas relacionadas especificamente com as voçorocas respondem por menos de 10% das publicações sobre a erosão do solo (Castillo e Gómez, 2016). Isso ocorre por uma série de dificuldades, tais como a natureza tridimensional dessas feições, bem como os vários fatores e processos que as afetam.

Os métodos baseados em visitas de campo foram amplamente utilizados para o mapeamento das voçorocas até que as imagens aéreas estivessem acessíveis para a fotointerpretação e processamento digital de imagens. A fotointerpretação de

imagens é uma técnica muito utilizada para identificação de voçorocas, porém pode ser morosa e subjetiva.

A detecção automática das voçorocas é de fundamental importância, pois elimina o subjetivismo da interpretação visual de imagens, bem como, possibilita diagnosticar mais rapidamente áreas extensas e de difícil acesso. Entretanto, o processamento digital das imagens no passado foi apoiado em métodos baseados no pixel, os quais possuem eficácia reconhecidamente limitada. Tal fato se justifica pela heterogeneidade espectral das voçorocas, causada pela presença de vegetação, solo exposto e sombras, sendo insuficiente utilizar apenas a informação espectral para discriminá-las das outras classes.

A detecção de voçorocas individuais foi apontada por Vrieling (2006), como um dos principais gargalos dentre as pesquisas que utilizam o sensoriamento remoto para avaliação dos efeitos da erosão hídrica. Tal fato se justifica, pois, as voçorocas individuais, em geral, apresentam maiores confusões espectrais e de forma, principalmente em ambientes antropizados. Visando buscar uma estratégia mais efetiva, a detecção de voçorocas teve uma mudança de unidade de análise do pixel para o objeto por volta de 2010.

O método da Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) tornou mais eficiente a detecção de voçorocas, uma vez que utiliza não apenas a informação espectral, mas também características texturais, topográficas, geométricas e de vizinhança para identificar o alvo. Dessa forma, a GEOBIA pressupõe a incorporação de um modelo de conhecimento atrelado ao processo de interpretação da cena.

Apesar de alguns autores terem obtido sucesso na detecção das voçorocas utilizando a GEOBIA, o potencial desse método ainda não foi totalmente explorado, sendo necessário maior aprofundamento de alguns aspectos-chave. Nesse sentido, predominam estudos que utilizam a GEOBIA com dados de alta resolução espacial, com menos de 5 metros de tamanho do pixel, para a detecção das voçorocas. No entanto, esses dados geralmente não são gratuitos e captam pequenas porções da superfície, tornando-se inviáveis para aplicação em extensas regiões.

No Brasil, a degradação causada por processos erosivos abrange várias regiões, especialmente o noroeste do Paraná, Planalto central, Oeste Paulista, Campanha Gaúcha, Triângulo Mineiro e Médio Vale do Paraíba do Sul (Botelho e Guerra, 2003). Visando realizar o diagnóstico do uso e cobertura do solo em todo o país o governo federal adquiriu imagens dos satélites RapidEye em 2012. Essas imagens possuem 5 metros de resolução espacial, sendo suficiente para identificar diversos fenômenos ambientais. Devido a essas características diversos estudos têm sido realizados visando o monitoramento ambiental, porém ainda são poucos os trabalhos relativos à detecção de voçorocas.

Outro aspecto ainda pouco discutido na literatura do mapeamento das voçorocas é a etapa da segmentação, a qual divide a imagem em objetos homogêneos e contíguos. A acurácia da segmentação afeta diretamente o desempenho da classificação, pois antecede a criação dos parâmetros que detectam os alvos. Apesar disso, a otimização da segmentação em estudos relacionados com voçorocas é usualmente realizada por medidas indiretas ou por inspeção visual, tornando essa etapa ainda ineficiente.

O presente estudo apresenta uma alternativa metodológica inovadora ao propor a utilização do *Segmentation Evaluation Index* (SEI) para avaliação dos objetos criados na etapa da segmentação de voçorocas. Esse índice utiliza critérios aritméticos e geométricos para encontrar a correspondência mais eficiente entre os objetos criados pelo modelo e a imagem referente às voçorocas. Para testar essa hipótese foram utilizadas imagens RapidEye e dados provenientes do modelo digital de elevação *Shuttle Radar Topography Mission* (SRTM).

2 OBJETIVOS

O objetivo principal do presente estudo é avaliar modelos de classificação orientada a objeto para o mapeamento das voçorocas a partir de imagens RapidEye e dados SRTM, em uma região do município de Uberaba, Minas Gerais.

2.1 Objetivos específicos

-Analisar a viabilidade da utilização de imagens RapidEye para a classificação semiautomática de voçorocas individuais;

-Realizar a otimização da segmentação das voçorocas baseado no índice SEI;

-Verificar a transferibilidade do modelo de detecção de voçorocas para outra área;

-Analisar a influência da declividade na acurácia do mapeamento de voçorocas;

-Comparar a classificação das voçorocas gerada por árvore de decisão com a classificação baseada no modelo empírico;

-Comparar a avaliação da acurácia do mapeamento a partir de pontos amostrais e a partir de polígonos;

-Verificar a eficiência do *software* InterIMAGE para segmentar e classificar as voçorocas por GEOBIA.

3 REVISÃO DA LITERATURA

3.1 Erosão dos solos

A erosão é um processo que pode ocorrer naturalmente no ambiente, mas também pode ser acelerada, devido à presença do homem. A erosão natural é um processo permanente, contribuindo para as características topográficas da Terra e para a formação dos solos. Já a erosão acelerada está associada a alterações na cobertura vegetal natural, sendo causada sobretudo pelo vento e pela água (Oliveira, 1988).

O processo de erosão hídrica inicia-se com o choque das gotas de chuva no solo, uma vez que essas dispersam a energia cinética provocando a desagregação das partículas superficiais do solo (efeito *splash*) (Pereira Júnior, 2013). Uma vez desagregadas e suspensas, as partículas do solo estão suscetíveis ao transporte. A facilidade desse transporte depende do tamanho da partícula, de modo que a argila, o silte e a matéria orgânica são as mais facilmente carregadas pelas águas (Lepsch, 2011).

Além de desagregar as partículas do solo, o efeito *splash* também pode ocasionar o selamento do mesmo, diminuindo a quantidade de poros e por consequência reduzindo sua capacidade de infiltração (Guerra, 2010). Na medida em que a intensidade da chuva é maior que a capacidade de infiltração começa o escoamento superficial, dando início ao transporte de sedimentos (Oliveira et al., 2005).

Uma vez iniciado o processo de escoamento superficial pode-se ter como consequência dois tipos de erosão: a laminar e a linear. A erosão laminar ocorre quando, após a desagregação do solo pelo impacto das gotas da chuva, há o transporte de partículas desagregadas em suspensão em um fino fluxo superficial, decorrente da turbulência provocada pelo impacto (Kinnel, 1998; Shaffer et al. 2001). As principais consequências da erosão laminar são a exposição do terreno, a remoção dos horizontes férteis do solo e o assoreamento de corpos d'água (Bacellar, 2000).

Já a erosão linear é causada pela concentração das linhas de fluxo das águas de escoamento superficial, as quais podem ser classificadas em sulcos, ravinas e voçorocas. Os diferentes processos erosivos variam no tempo e no espaço, podendo ocorrer em poucas horas (em um evento chuvoso), como podem ser sazonais ao longo do ano, ou a longo prazo, refletindo os efeitos da ocupação humana (Guerra, 1994).

À medida que a água escoar em direção a depressão do relevo do terreno e possui energia para formar canais, desenvolvem-se os sulcos (Machado, 2006). O termo sulco é utilizado quando se pode recuperar o entalhe erosivo por operações normais de preparo do solo (Cerri et al., 1997). Os sulcos se encaixam na superfície, percorrendo a direção de maior inclinação da vertente, e assim a velocidade da água causa erosão cada vez mais intensa (Bigarella e Mazuchowski, 1985).

O estágio seguinte do processo erosivo mais intenso é a formação das ravinas, as quais se constituem em canais visíveis ou canaletas pequenas, mas bem definidas, onde ocorre a concentração do fluxo (Araújo et al., 2008). As definições de ravina podem variar de acordo com o comportamento hidrológico, morfologia, posição topográfica e relação com as atividades antrópicas. Apesar da utilização de diferentes propriedades, essas definições estão quase sempre associadas à erosão acelerada (Franco, 2015). No estágio mais avançado, Araújo et al. (2008) definem as voçorocas em canais visíveis onde ocorrem a concentração de água que, ao escorrer encosta abaixo, aprofunda os sulcos.

As ravinas normalmente possuem a forma mais alongada, com profundidades variáveis e raramente são ramificadas (Almeida Filho, 2000). Segundo Camapum de Carvalho et al (2006), o termo ravina deveria ser usado para canais com profundidades superiores a 10 cm e inferiores a 50 cm. O limite de 50 cm está relacionado com a estabilidade do talude pois, mesmo para solos granulares, a matéria orgânica e a presença de raízes na camada superficial asseguram uma certa estabilidade até essa profundidade.

3.1.1 Voçorocas

O nome voçoroca tem origem na língua tupi-guarani, *ibiçoroca*, *yby* = terra + *coroca*=romper (Oliveira e Meis, 1985). Outros termos utilizados para essas feições erosivas são *boçorocas*, *grotas* e *esbarrancados* (Machado et al., 2006). Os limites para a distinção entre as ravinas e as voçorocas ainda são controversos na literatura nacional, sendo utilizados critérios geométricos ou pela presença do lençol freático. Em geral, predominam as classificações de caráter geométrico (Lima, 2003). Guerra (1998), por exemplo, define as voçorocas como canais com largura e profundidade superiores a 50 cm.

De acordo com a literatura internacional ravinas e voçorocas são conhecidas como *gullies*, não havendo distinção entre a atuação do lençol freático para sua definição (Camapum de Carvalho et al., 2006). Por outro lado, é frequente a classificação das voçorocas em efêmeras, permanentes ou clássicas, e de ribanceira. As voçorocas permanentes em áreas agrícolas são definidas como canais profundos, os quais dificilmente são removidos por equipamentos agrícolas, podendo variar de 0,5 até 30 m de profundidade (Soil Science Society of America, 2008). As voçorocas efêmeras são definidas como pequenos canais de drenagem, que podem se transformar em voçorocas permanentes se não forem preenchidos (Smith, 1993). Já as voçorocas de ribanceira são canais formados devido à altura da queda da água, resultante da diferença de nível entre a área de drenagem e o curso d'água, em locais com margens erodíveis (Vandekerckhove et al., 2000).

A gênese das voçorocas ocorre por erosão superficial, erosão subsuperficial e movimentos de massa (Bacellar, 2006). Esse processo pode ocorrer naturalmente, mas também pode ser induzido e agravado pelas atividades humanas (Casalí et al., 2009). De acordo com Bacellar (2006) existem alguns fatores que definem uma maior propensão ao surgimento de voçorocas, dentre os quais destacam-se: fatores geomorfológicos; fatores geológicos, fatores pedológicos, fatores climáticos, e fatores antrópicos.

Em relação ao relevo, o surgimento das voçorocas está condicionado à declividade, ao comprimento da rampa e à forma da encosta, que favorecem maior

velocidade, volume e concentração da enxurrada (Machado et al., 2006). Por esse motivo, as voçorocas são feições comuns em regiões montanhosas ou com encostas íngremes (Valentin et al., 2005). No entanto, a velocidade do escoamento superficial é afetada não só pela declividade, mas também pelo comprimento da encosta, de modo que encostas mais longas também proporcionam maior volume e velocidade de escorrência (Evelpidou e Figueiredo, 2009).

Outro aspecto que influencia o processo de erosão é a morfologia da encosta. Assim, as formas côncavas favorecem a convergência das águas, criando uma erosão mais localizada, que favorecem a formação de sulcos, ravinas e voçorocas. Já as formas convexas favorecem a divergência das águas, proporcionando uma erosão mais uniforme (Gonçalves, 2002). A Figura 1 ilustra os tipos de relevo.

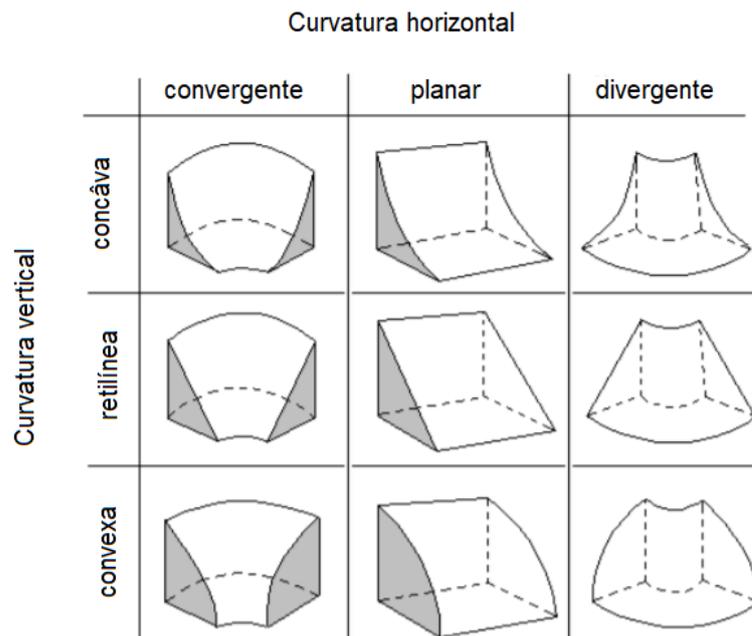


Figura 1. Caracterização das formas do relevo.
Fonte: Adaptada de Dikau (1990).

O clima influencia diretamente nos processos erosivos, agindo na desagregação da rocha e na formação dos solos. Os aspectos climáticos mais atuantes no desenvolvimento dos solos são a precipitação e a temperatura (Couto, 2015). Desse modo, a erosão pode ser maior ou menor em função da duração, intensidade e frequência das precipitações. A erosividade expressa a capacidade

das chuvas de causar erosão pela desagregação e transporte das partículas do solo, ocasionada pelo impacto das gotas da chuva e pelo escoamento superficial da água (Lal, 1994). Para a obtenção da erosividade da chuva com boa precisão Wischmeier e Smith (1978) recomendam a utilização de uma série histórica de dados provenientes de uma estação meteorológica com no mínimo 20 anos.

Embora o processo dominante do avanço das voçorocas esteja associado ao escoamento superficial, o aumento de fluxo da água no sub-solo durante os períodos chuvosos também elevam as taxas de erosão sub-superficiais como “piping” e escorregamentos (Ide, 2009). A erosão em “piping” pode se desenvolver a centenas de metros de distância das voçorocas, enfraquecendo o solo e criando regiões de percolação preferencial, podendo haver o afundamento de parte da terra (Fendrich et al., 1997).

As características litológicas do substrato rochoso, juntamente com as condições climáticas estabelecem a susceptibilidade do material ao processo erosivo, uma vez que estão diretamente relacionadas ao tipo de solo e ao relevo (Couto, 2015). As forças tectônicas estão relacionadas ao desenvolvimento do relevo, podendo criar fissuras nas rochas sem necessariamente causar deslocamentos. Essas fissuras atuam como ponto de partida para o processo de intemperismo, as quais podem se desenvolver em depressões, tornando-se locais de fluxo preferencial que podem culminar em voçorocas (Valentin et al., 2005).

A erodibilidade do solo corresponde à vulnerabilidade do solo aos processos erosivos. Essa característica é resultante do efeito integrado dos processos que regulam a recepção da chuva e sua resistência para desagregação de partículas e seu transporte. Tais processos se baseiam nas propriedades do solo, assim como a distribuição do tamanho das partículas, estabilidade estrutural, natureza do minerais e conteúdo de matéria orgânica (Lal, 1988).

A textura influencia a erodibilidade do solo, sendo que uma chuva de baixa intensidade pode causar o desprendimento de partículas grandes de um solo arenoso, podendo um pequeno volume de escoamento superficial arrastar uma grande quantidade de solo. Em contrapartida, alguns solos argilosos, apesar de

apresentarem infiltração reduzida, sofrem menor erosão devido à maior força de coesão entre as partículas (Bertoni e Lombardi Neto, 1990).

A matéria orgânica incorporada no solo possibilita maior agregação e coesão das partículas, deixando o solo mais estável na presença de água e com maior macroporosidade (Salomão, 2005). O aumento da estabilidade dos agregados aumenta a resistência ao impacto das gotas da chuva, diminuindo a erosão por salpicamento, bem como aumenta a taxa de infiltração, resultando na redução do escoamento superficial (Guerra, 1994).

A erosão causada pelas voçorocas tem sido reportada com dimensões alarmantes em muitos países, de modo que na maioria dos casos está ligada a atividades humanas insustentáveis (Smolska, 2007). Em geral, ocorre a retirada da cobertura vegetal natural, alterando o regime de escoamento superficial e subsuperficial de modo a potencializar os processos erosivos (Infanti Jr. e Fornasari Filho, 1998). No meio urbano, as voçorocas são formadas pelo aumento do volume das águas superficiais e por lançamentos indevidos das drenagens das águas pluviais (Camapum de Carvalho et al., 2006). Assim, apenas em algumas ocasiões os fatores naturais foram considerados como principais responsáveis por esse fenômeno (Wells e Andriamihaja, 1993).

As voçorocas geralmente resultam em consequências negativas severas, tendo-se em vista a degradação intensa do solo e das áreas agricultáveis, alteração do fluxo de transporte de sedimentos, desestabilização estrutural e aumento do escoamento superficial (Takken et al., 2008; Chen et al., 2016). A erosão causada por voçorocas permanentes excede significativamente as taxas de solos perdidas na agricultura convencional, que já estão muito acima das taxas de formação do solo (Castillo e Gómez, 2016). Embora ocupem, em geral, menos de 5% da área de captação da bacia, a erosão causada pelas voçorocas representam a mais importante forma de perda de solos em diversos ambientes (Ionita et al., 2015). Nesse sentido, Castillo e Gómez (2016) apontam alguns estudos que avaliam as taxas de perda específica de solos: Derosé et al. (1998) com $1550 \text{ t}\cdot\text{ha}^{-1}\cdot\text{y}^{-1}$ na Nova Zelândia; Mieth e Bork, (2005) com $398 \text{ t}\cdot\text{ha}^{-1}\cdot\text{y}^{-1}$ na Islândia e Tebebu et al. (2010) com $530 \text{ t}\cdot\text{ha}^{-1}\cdot\text{y}^{-1}$ na Etiópia.

3.2 Análise de Imagens Baseada em Objetos Geográficos

Devido a necessidade de se obter melhores resultados nos estudos de uso e cobertura do solo foi necessária a criação de uma nova forma de análise de imagens, a qual muda o foco do pixel para o objeto (Blaschke e Strobl, 2001). Assim, surge a Análise de Imagens Baseada em Objeto (*Object-Based Image Analysis - OBIA*), que se apoia em métodos já existentes (segmentação, detecção de bordas, extração de feições e classificação) para integrar informações espectrais e conceitos espaciais em diferentes escalas (Blaschke et al. 2014).

Outros termos utilizados para a mesma área do conhecimento são: Análise Orientada a Objetos, Objeto-Específico, e Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) (Hay et al., 1996; Blaschke et al., 2004, 2014). A utilização do termo GEOBIA se faz necessária para diferenciar o campo de atuação desse método, o qual é uma sub-disciplina da Ciência da Informação Geográfica. Ao introduzir o termo “geográfico” fica mais claro para outras áreas do conhecimento como Visão Computacional, Ciências dos Materiais ou Imageamento Biomédico que a utilização de imagens provenientes do sensoriamento remoto ‘modela’ ou ‘captura’ porções da superfície terrestre (Blaschke et al. 2014).

Devido à mudança da unidade de análise do pixel para objetos, Blaschke e Strobl (2001) argumentam que a análise baseada em objeto é superior ao tradicional método baseado em pixel. Informações adicionais, como propriedades geométricas e relação espacial com objetos vizinhos permitem uma abordagem similar àquela realizada na interpretação visual de imagens aéreas, mas em um modo reprodutível e controlado (Shruthi et al., 2012).

Assim, a GEOBIA fornece uma alternativa para situações em que as propriedades espectrais do alvo não são únicas, mas a forma e vizinhança podem ser distintas. Os resultados dos mapas obtidos por meio desse método se tornam mais fáceis de interpretar, uma vez que os objetos resultantes são parcelas homogêneas da terra que já existem. Os objetos gerados representam as entidades relevantes que são distinguíveis em uma imagem sendo, portanto, dependentes da escala (Blaschke et al., 2014).

O *software* eCognition introduziu a GEOBIA em um ambiente SIG, tornando possível a disseminação de pesquisas nesse campo. Desde então, esse método de análise tem sido amplamente utilizado para classificação do uso e cobertura da terra, principalmente para imagens de alta resolução espacial (Ribeiro et al., 2011). Devido à crescente demanda dos usuários, outros *softwares* comerciais como o ENVI e Erdas IMAGINE incorporaram em seus pacotes a extração de feições, bem como componentes de análise. Entretanto, o alto custo desses pacotes inviabiliza a utilização desse método para muitos usuários (Vu, 2012). Diante disso, é crescente o desenvolvimento de sistemas open source voltados à GEOBIA, como os *softwares* *Interpreting Images Freely* (InterIMAGE) (Costa et al., 2008) e *Geographic Data Mining Analyst* (GeoDMA) (Korting, 2012).

De modo geral, o processo de mapeamento por meio da GEOBIA se baseia na seguinte sequência de procedimentos: criação da rede semântica, segmentação, criação das regras para a separação das classes e avaliação da acurácia. A seguir, serão apresentados os principais aspectos relacionados a cada etapa da GEOBIA.

3.2.1 Criação da rede semântica

A rede semântica é a estrutura pela qual o conhecimento é expresso na GEOBIA, sendo representada pela criação de arcos e nós (Antunes, 2003; Francisco e Almeida, 2012). Cada nó, ou classe, representa um conceito do mundo real e cada arco representa a relação entre os nós (Novack, 2009). Assim, os conceitos da rede semântica são baseados em hierarquias, de modo que o conhecimento é representado por níveis de segmentação. Dessa forma, os sub-objetos (objetos gerados nas escalas menores) estão contidos nos super-objetos (objetos gerados nas escalas maiores), a partir da junção dos sub-objetos (Tedesco et al., 2014).

Os objetos criados obedecem às regras estabelecidas em toda a rede hierárquica, ou seja, cada objeto reconhece os super-objetos, os sub-objetos, bem como os objetos do mesmo nível (Benz et al., 2004). Essa informação topológica representa uma das maiores vantagens apresentadas pela análise de imagens orientada a objetos (Pinho, 2005).

O processo de criação da rede semântica pode se dar de duas formas: (a) heurísticamente pelo usuário, realizando testes para elencar os atributos e limiares mais relevantes e (b) automaticamente, através de técnicas de mineração de dados, as quais utilizam algoritmos para extração do conhecimento de um grande volume de dados (Rodrigues, 2014).

3.2.2 Segmentação

O objetivo da segmentação da imagem proveniente do sensoriamento remoto é criar objetos que possuam uma determinada homogeneidade em uma certa escala (Wang et al., 2014). A segmentação de imagens, ao ser incorporada pela GEOBIA, introduziu alguns avanços na compreensão das regiões criadas (Blaschke e Strobl, 2001; Blaschke, 2010). Dessa forma, os pixels agrupados são reconhecidos como objetos, dotados de significado e identidade. Ao contrário dos segmentos ou regiões, os objetos podem ser identificados não apenas pelas suas propriedades, mas também pela sua própria existência. Nesse sentido, dois objetos com as mesmas características permanecem únicos e independentes, uma vez que apresentam relações contextuais diferentes (Rodrigues, 2014).

Os critérios de segmentação incluem principalmente os parâmetros de escala e critérios de homogeneidade. A escala corresponde à dimensão espacial em que entidades, padrões e processos podem ser observados e caracterizados (Wang, 2010). Entre os fatores de entrada do processo de segmentação, a escala é considerada o mais crítico e, por esse motivo, muitos estudos tem o foco na otimização desse parâmetro (Liu et al., 2017). O valor da escala é importante pois controla o tamanho relativo dos objetos gerados, afetando diretamente os processos de segmentação e acurácia da extração da informação. De modo geral, um baixo valor desse parâmetro é utilizado para identificar pequenas feições, enquanto um alto valor é necessário para segmentação de feições maiores (Wang et al., 2014).

Para D'Oleire-Oltmanns (2014), a escolha da escala está relacionada com a resolução do pixel, uma vez que a extensão espacial mínima do objeto a ser identificado deve ser compatível com a resolução do dado de entrada. Assim, o real detalhamento das feições na imagem envolve a combinação da resolução e da

escala com que a imagem foi vista ou impressa (Shruthi et al., 2015). Nesse sentido, Blaschke et al. (2014) comentam que a GEOBIA não está limitada apenas a imagens de alta resolução, podendo também ser aplicada em imagens com pixels de tamanho maior, necessitando apenas de ajustes do parâmetro escala em relação ao tamanho dos objetos detectáveis.

Já os critérios de homogeneidade podem ser divididos em dois grupos: cor e forma. Os pesos desses parâmetros são complementares, ou seja, ao modificar o valor do peso da forma, o analista define o valor do peso atribuído a cor, de modo que somados devem resultar no valor um (Trimble, 2012). A forma, por sua vez, pode ser subdividida em dois parâmetros: suavidade e compacidade. A suavidade representa o grau de irregularidade do contorno de um objeto imagem. Já a compacidade representa o quão compacto estão os pixels dentro de um objeto imagem (Baatz e Schape, 2000).

O processo de segmentação é iniciado com cada pixel formando um segmento ou região. O número de segmentos cresce na medida em que são unidos com seus vizinhos. Assim, a fusão de dois segmentos é baseada na heterogeneidade espectral (em função da cor) e na heterogeneidade espacial (em função da forma). Antes de ocorrer a união dos objetos o fator de fusão (f) é calculado para cada um dos vizinhos do segmento selecionado de modo que, aquele que receber o menor valor de (f) é o escolhido para a união. Entretanto, a fusão apenas ocorre se estiver abaixo de um determinado limiar, o qual é definido pelo quadrado do parâmetro de escala. O processo continua unindo segmentos até que não haja mais possibilidade de união (HAPP et al., 2009). A Equação 1 ilustra o critério geral de fusão dos objetos:

$$f = w \cdot h_{\text{cor}} + (1-w) \cdot h_{\text{forma}} \quad (1)$$

em que,

f = critério de fusão;

w = peso dado à variável;

h_{cor} = heterogeneidade espectral;

h_{forma} = heterogeneidade espacial.

A heterogeneidade espectral é obtida a partir da soma ponderada dos desvios padrões de cada banda, para uma determinada região. A heterogeneidade para a cor é dada pela Equação 2:

$$h_{\text{cor}} = \sum_c w_c \cdot (n_a \cdot \sigma_c - (n_1 \cdot \sigma_1 + n_2 \cdot \sigma_2)) \quad (2)$$

em que,

c = bandas;

n_a = tamanho do possível objeto a ser formado;

n_1 e n_2 = tamanho dos objetos;

σ_1 e σ_2 = desvio padrão dos objetos.

A Equação 3 determina a heterogeneidade espacial (h_{forma}):

$$h_{\text{forma}} = w_{\text{cp}} \cdot h_{\text{cp}} + (1 - w_{\text{cp}}) \cdot h_{\text{sv}} \quad (3)$$

em que,

w_{cp} = peso atribuído a compacidade;

h_{cp} = heterogeneidade para a compacidade;

h_{sv} = heterogeneidade para a suavidade.

A compacidade da segmentação é obtida a partir da razão entre o perímetro de um objeto pela raiz quadrada do número de pixels. A Equação 4 demonstra a heterogeneidade da compacidade:

$$h_{cp} = n_a \cdot \frac{l_a}{\sqrt{n_a}} - \left(n_1 \cdot \frac{l_1}{\sqrt{n_1}} + n_2 \cdot \frac{l_2}{\sqrt{n_2}} \right) \quad (4)$$

em que,

n_a = tamanho do possível objeto a ser formado (em número de pixels);

n_1 e n_2 = tamanho dos objetos (em número de pixels);

l_a = perímetro do possível objeto a ser formado;

l_1 e l_2 = perímetros dos objetos.

A suavidade é obtida a partir da razão entre o perímetro do objeto e o retângulo envolvente. Equação 5 demonstra a heterogeneidade da suavidade:

$$h_{sv} = n_a \cdot \frac{l_a}{b_a} - \left(n_1 \cdot \frac{l_1}{b_1} + n_2 \cdot \frac{l_2}{b_2} \right) \quad (5)$$

em que,

b_a = o perímetro do retângulo envolvente do possível objeto a ser formado;

b_1 e b_2 = os perímetros dos retângulos envolventes dos objetos originais;

l_a = o perímetro do objeto a ser formado;

l_1 e l_2 = os perímetros dos objetos originais.

O processo de segmentação exige atenção pois não há valores padronizados para as variáveis do algoritmo (Coutinho, 1997). O valor ótimo para a segmentação é aquele que delimita os limites do objeto geográfico de modo claro, sem que haja divisões do mesmo (Wang et al. 2014). Conforme destacado por Liu et al. (2012), o processo de segmentação pode gerar segmentos correspondentes a um objeto-alvo ou partes dele, podendo ocorrer várias discrepâncias entre o polígono de referência e o segmento resultante da classificação. Em geral, os métodos de avaliação da segmentação incluem a inspeção visual, avaliação quantitativa, e avaliação indireta (Li e Xiao, 2007).

Embora possa ser subjetiva e qualitativa, a inspeção visual ainda é o método de avaliação da segmentação mais usado. Já a avaliação indireta permite inferir a qualidade da segmentação, porém não fornece uma indicação direta da acurácia da

segmentação (Yang et al., 2015). Por outro lado, a avaliação quantitativa vem recebendo maior atenção nos trabalhos relacionados à GEOBIA por causa da quantidade de informações geradas, como a quantificação da super-segmentação e sub-segmentação (Yang et al. 2015). Nesse sentido, o conjunto de métodos denominados de Discrepância Empírica tem se mostrado mais eficiente dentre os métodos de avaliação quantitativa (Zhang, 1996). Esses métodos baseiam-se na comparação entre o polígono de referência e os objetos criados na segmentação.

De modo geral, as medidas de discrepâncias propostas rotulam um segmento como correspondente ao objeto-alvo se a área de interseção entre o polígono de referência e o segmento for maior que metade da área do polígono de referência ou maior que metade da área do segmento candidato (Yang et al., 2015). Essa medida é denominada sobreposição unilateral de 50% e foi utilizada por diversos autores (Clinton et al., 2010; Liu et al., 2012; Yang et al., 2014).

Shruthi et al. (2014), visando otimizar o processo de segmentação de sistemas de voçorocas na região semi-árida do Marrocos, estabeleceram como critério de correspondência que pelo menos 50% do segmento criado estivesse contido na área da voçoroca real. No entanto, essa regra permite que pequenos segmentos sejam considerados correspondentes à classe voçoroca, podendo enviesar a extração de informações na etapa de criação do modelo, principalmente com relação aos parâmetros geométricos e texturais.

Para superar as fragilidades apresentadas pelo método da sobreposição unilateral de 50%, Yang et al. (2015) criaram uma medida de discrepância denominada *Segmentation Evaluation Index* (SEI), a qual avalia a correspondência de um objeto a partir de critérios aritméticos e geométricos. A avaliação aritmética é realizada a partir do cálculo do SEI para cada objeto, analisando o quão próximo a área do objeto criado pela segmentação se sobrepôs ao objeto de referência. A Equação 6 ilustra o cálculo do índice SEI para um segmento:

$$SEI_i = \sqrt{\frac{\left(1 - \frac{\text{area}(r_i \cap s_i)}{\text{area}(r_i)}\right)^2 + \left(1 - \frac{\text{area}(r_i \cap s_i)}{\text{area}(s_i)}\right)^2}{2}} \quad (6)$$

em que,

SEI_i - índice de avaliação da segmentação do objeto i ;

r_i - área do alvo de referência;

s_i - área do objeto obtido no processo de segmentação.

O índice SEI_i é calculado para cada objeto e posteriormente é calculada a média, obtendo o SEI para toda a cena. Os valores do SEI variam entre 0 e 1, sendo 0 a sobreposição perfeita entre o objeto e o alvo de referência. No entanto, esse índice estabelece uma condição geométrica a ser analisada em cada objeto, denominada de sobreposição bilateral de 50%, a qual considera um segmento como correspondente quando a interseção entre o polígono de referência e o segmento candidato for maior que 50% do polígono de referência e maior que 50% do segmento candidato. Os segmentos que não atenderam a regra de sobreposição bilateral de 50% receberam valor de SEI igual a 1, o qual corresponde a pior segmentação. Já os segmentos que atenderam a regra resultaram em valores que puderam chegar até 0.

Em sua revisão sobre os métodos de avaliação da segmentação, Chen et al. (2018) afirmam que a avaliação supervisionada é superior à análise visual, gerando resultados mais precisos. Por outro lado, os autores comentam que a necessidade da geração manual dos dados de referência pode consumir muito tempo, além de trazer certa subjetividade. No entanto, os autores afirmam que, em geral, os métodos de avaliação da segmentação na GEOBIA ainda precisam de melhorias, uma vez que todos apresentam algum tipo de deficiência.

3.2.3 Criação das regras para separação das classes

Os dados de entrada utilizados em um determinado estudo podem fornecer vários parâmetros, os quais podem ser redundantes ou irrelevantes para a

classificação. As variáveis que possuem alta correlação não agregam informação ao modelo, e as irrelevantes não possuem informação útil (Merschmann, 2007). Essas características podem afetar significativamente o desempenho dos algoritmos de aprendizado (Hall, 1998). Nesse sentido, a etapa de criação do modelo é utilizada para escolher um conjunto de atributos que melhor descrevam os objetos alvos (Kohavi e John, 1997).

A escolha das regras para classificação dos alvos pode ser manual, por meio de tentativa e erro, ou automático, por meio de algoritmos de mineração de dados. Assim como na etapa da segmentação, o processo de criação manual do modelo de classificação pode se tornar subjetivo e demandar muito tempo para encontrar os parâmetros mais relevantes. Se por um lado a definição manual dos limiares torna o modelo flexível e adaptável a diferentes regiões, por outro existe a limitação de não se tornar transferível, devido à diversidade de feições para se identificar ao se alterar a área de estudo (Shruthi et al. 2015).

Visando tornar a etapa da criação do modelo mais rápida é crescente o uso de técnicas de mineração de dados nos estudos de GEOBIA (Tedesco, 2015). A mineração de dados pode ser definida como o processo de análise de dados a partir de perspectivas distintas e resumida em informações úteis (Fayyad et al., 1996; Witten et al., 2011). Dessa forma, os algoritmos de mineração de dados se tornam importantes para explorar dados visando criar modelos de conhecimento, os quais expressam padrões de comportamento dos dados (Witten et al. 2011).

A utilização das ferramentas de mineração de dados no sensoriamento remoto permite diminuir o tempo de processamento dos dados bem como aumentar o potencial de análise. Essas características são importantes devido ao avanço da tecnologia dos sensores, os quais podem gerar uma grande quantidade de dados (Korting et al., 2011). Existem diversos métodos de mineração de dados como por exemplo os baseados em redes neurais, lógica nebulosa, algoritmos genéticos e indução de árvores de decisão (Goldschmidt e Passos, 2005).

As árvores de decisão pertencem à classe de algoritmos supervisionados de mineração de dados, de modo que as classes devem ser previamente conhecidas.

O método de classificação consiste na divisão do conjunto em subgrupos-filhos, construindo uma árvore da raiz para as folhas. O algoritmo determina uma regra de classificação em cada passo, selecionando uma variável e o seu limiar. Esse processo é repetido até que não seja mais possível encontrar novas variáveis que permitam divisões dos dados estatisticamente significantes, objetivando dividir os dados em grupos homogêneos (Bento, 2016).

Informações sobre os tipos de solos, geologia, uso e ocupação do solo são consideradas importantes na detecção das voçorocas, porém nem sempre estão disponíveis em detalhamento suficiente (Shruthi et al., 2014). Por esse motivo, a detecção de voçorocas por GEOBIA geralmente utiliza como dados de entrada imagens, com informações espectrais dos alvos, e modelos digitais do terreno, com informações altimétricas, ou ainda a associação de ambos.

Devido à confusão espectral das voçorocas com outros alvos da imagem, os estudos que utilizam apenas dados ópticos, como imagens de satélites e fotografias aéreas, devem inserir no modelo, além de informações espectrais, outros parâmetros que permitam a distinção dessas feições. Karami et al. (2015), ao utilizarem apenas dados ópticos, constataram que o aumento da acurácia do mapeamento de voçorocas se deu em função do emprego dos parâmetros de textura e forma. Dentre outros parâmetros texturais, o Gray Level Co-occurrence Matrix (GLCM) (Bekkar et al., 2013), tem sido utilizado com frequência nos modelos de detecção de voçorocas (Wang et al., 2014; Tedesco, 2015; Shruthi et al., 2015; Rahmati et al., 2017).

Wang et al. (2014) utilizaram apenas ortofotos de alta resolução espacial para detecção de pequenas voçorocas na bacia Beiyanzikou, China. Para isso, foram utilizados parâmetros espectrais, geométricos e texturais, extraídos das imagens. Os autores compararam os pontos coletados no campo com as bordas das voçorocas classificadas e obtiveram uma diferença média de 0,3166 m e variância de 0,2116, indicando que a GEOBIA pode efetivamente classificar as voçorocas.

Poesen et al. (2003) constataram que há uma forte correlação entre combinações de dados de declividade e área de contribuição de captação com a

formação das voçorocas. Devido às transformações no relevo, causadas pelo transporte de sedimentos, é frequente o uso de parâmetros derivados do MDE para detecção de voçorocas, a partir de dados laser (Perroy et al., 2010); estereoscopia de imagens orbitais (Shruthi et al., 2012), ou Veículo Aéreo Não Tripulando-VANT (Scholte-Albers, 2015)

Alguns autores utilizaram apenas a informação altimétrica para detectar as voçorocas. Johansen et al. (2012), criaram um modelo baseado na detecção de bordas das voçorocas a partir do sensor LIDAR e obtiveram acurácia global de 92,3%. Por outro lado, Eustace et al. (2009), ao utilizar o mesmo sensor (LIDAR), obtiveram acurácia global de 75% e Kappa 0,52. Já Scholte-Albers (2015), recomenda a combinação de dados ópticos e altimétricos para a detecção das voçorocas em seu estágio inicial, uma vez que o modelo criado a partir de um MDE foi mais eficiente para voçorocas grandes. No entanto, o autor enfatiza que a combinação de dados de alta resolução espacial requer grande capacidade de processamento computacional, principalmente quando são analisadas grandes porções do terreno.

3.2.4 Avaliação da acurácia

O objetivo da avaliação da acurácia da classificação é analisar a coerência do resultado gerado pelo modelo em comparação com a realidade. A forma mais comum de representar a acurácia dos dados provenientes do sensoriamento remoto é por meio da matriz de erros ou matriz de confusão. Essa, por sua vez, é uma matriz quadrada formada por linhas e colunas que expressam o número de unidades amostrais de uma categoria em relação à verdade de campo (Congalton, 1991). Em geral, as colunas representam os dados de referência enquanto as linhas representam a classificação gerada por algum método de classificação automática (Passo, 2017). A Figura 2 ilustra a estrutura de uma matriz de confusão.

		j = Colunas (Referência)			Total de Linhas n_{i+}
		1	2	k	
i = Linhas (Classificação)	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Total de Colunas n_{+i}		n_{+1}	n_{+2}	n_{+k}	n

Figura 2. Estrutura da matriz de confusão. Fonte: Passo (2017).

A partir da matriz de confusão podem ser extraídos os coeficientes de concordância totais e individuais. Dentre os coeficientes de concordância totais destacam-se a Acurácia Global e o Kappa. A Acurácia Global é calculada a partir da relação entre as amostras corretamente classificadas e o número total de amostras (Persello e Bruzzone, 2010). A Equação 7 apresenta o cálculo da Acurácia Global:

$$P_0 = \frac{\sum_{i=1}^M n_{ii}}{N} \quad (7)$$

em que,

P_0 = Acurácia Global

M = número de classes;

n_{ii} = elementos da diagonal principal;

N = número total de amostras.

Por outro lado, o índice Kappa considera não apenas os elementos da diagonal principal, como na Acurácia Global, mas todos os elementos da matriz de erros. O índice Kappa (K) pode ser determinado pela Equação 8.

$$K = \frac{P_0 - P_c}{1 - P_c} \quad (8)$$

em que,

P_0 = Acurácia Global;

P_c = proporção de unidades que concordam por casualidade, a qual é expressa pela Equação 9:

$$P_c = \frac{\sum_{i=1}^M n_{i+} n_{+i}}{N^2} \quad (9)$$

em que,

M = número de classes;

n_{i+} = total de elementos classificados para uma categoria i ;

n_{+i} = total de elementos de referência amostrados para uma categoria i ;

N = número total de amostras.

O resultado gerado pelo índice Kappa pode ser interpretado a partir da Tabela 1.

Tabela 1. Classificação do índice Kappa.

Estatística Kappa	Desempenho
< 0	Péssimo
$0 < K \leq 0,2$	Ruim
$0,2 < K \leq 0,4$	Razoável
$0,4 < K \leq 0,6$	Bom
$0,6 < K \leq 0,8$	Muito Bom
$0,8 < K \leq 1$	Excelente

Fonte: Adaptado de Landis e Koch (1977).

Por outro lado, os índices de concordância individuais representam as acurácias das categorias individuais, de modo a fornecer informações específicas geradas pela classificação. Assim, a matriz de erros também pode fornecer a acurácia do produtor e a acurácia do usuário. A acurácia do produtor indica o quão bem os pixels de uma classe conhecida no terreno foram classificados. Já a

acurácia do usuário indica a probabilidade de um pixel classificado em uma classe represente realmente aquela categoria no terreno (Lillesand e Kiefer, 1994).

Radoux et al. (2011) afirmam que os métodos clássicos de amostragem baseados em pixels não correspondem ao mesmo conceito de objetos, tornando menos apropriados na classificação por GEOBIA. Ao utilizar o objeto como unidade de referência, é possível validar os alvos classificados em relação às condições de forma, borda, tema e posição, tornando o resultado mais próximo da realidade.

Visando melhorar a avaliação da acurácia da GEOBIA alguns autores desenvolveram métodos que comparam de forma mais apropriada os resultados da classificação com os dados de referência (Möller et al., 2007, 2013; Radoux et al., 2011; Lizarazo, 2014). Em relação aos estudos com foco nas voçorocas, essa análise é comumente realizada comparando-se os segmentos resultantes da classificação com os dados vetorizados manualmente (Shruthi et al., 2011, 2014; d'Oleire-Oltmanns et al., 2013, 2014; Karami et al., 2015).

4 MATERIAL E MÉTODOS

4.1 Área de estudo

A área de estudo está localizada em uma região com alta incidência de voçorocas no município de Uberaba, Minas Gerais. A região apresenta diversos tipos de uso e cobertura do solo, com predominância do uso agrícola e pecuário. A Figura 3 ilustra as duas regiões selecionadas para o mapeamento das voçorocas. O tamanho das áreas de estudos foi escolhido visando reduzir o tempo de processamento da classificação. A área de estudo 1 (Figura 3A) possui 4,36 km² e a área de estudo 2 (Figura 3B) possui 3,77 Km².

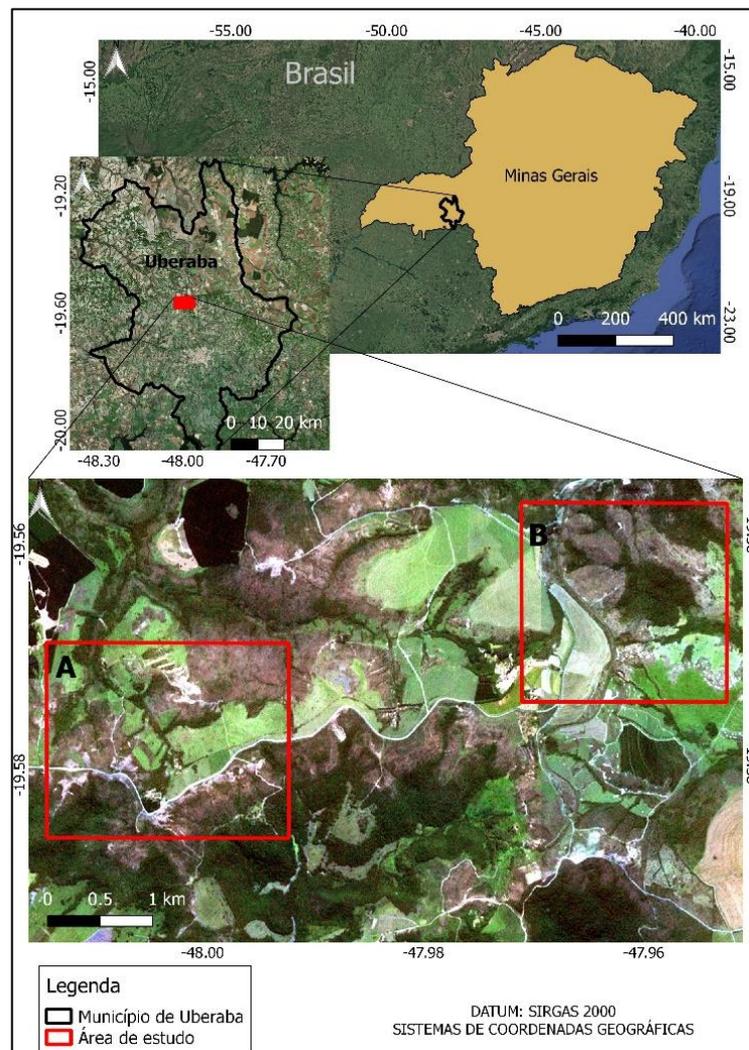


Figura 3. Localização das áreas de estudo: a) área 1 e b) área 2.

4.2 Material

Dados:

- Duas imagens multiespectrais do satélite RapidEye, adquiridas gratuitamente no site do Ministério do Meio Ambiente (MMA), por meio de uma parceria entre o governo federal e instituições públicas de ensino e pesquisa. As imagens RapidEye foram selecionadas em função de sua resolução espacial (5 metros) e pela ausência de estudos relacionados com a detecção de voçorocas por GEOBIA a partir de sensores desta plataforma orbital. A data de aquisição das imagens foi em 05/02/2014, para a área 1, e 27/05/2014, para a área 2. As informações foram obtidas em cinco faixas: banda 1 (440-510nm), banda 2 (520-590nm), banda 3 (630-690nm), banda 4 (690-730nm) e banda 5 (760-880nm).
- Dois modelos digitais de elevação *Shuttle Radar Topography Mission* (SRTM), com 30 m de resolução espacial. Para cobrir toda a extensão da área de estudo foi necessário adquirir, no sítio eletrônico do *United States Geological Survey* (USGS), duas cenas SRTM: SRTM1S20W048V3 e SRTM1S20W049V3, obtidas em 23/09/2014.
- Dois arquivos no formato shapefile utilizados na avaliação da acurácia: um shapefile de polígono, criado a partir da vetorização manual das voçorocas; e um shapefile de pontos, criados aleatoriamente para cada classe.

Softwares:

- InterIMAGE 1.43 – para otimização da segmentação, implementação da rede semântica e classificação das imagens.
- Terraview 4.2.2 – para mineração dos dados, classificação por árvore de decisão (por meio da ferramenta Geodma), e geração de amostras aleatórias estratificadas para validação.
- Qgis 2.14.13 – para o pré-processamento dos dados, validação dos resultados e geração dos mapas.
- Google Earth Pro – para auxiliar na identificação dos alvos.

4.3 Métodos

Os procedimentos metodológicos desenvolvidos no presente estudo seguiram as seguintes etapas: pré-processamento dos dados; definição das classes de uso e cobertura do solo; classificação a partir do modelo empírico; classificação por árvore de decisão e avaliação da acurácia. A Figura 4 ilustra cada passo de forma detalhada, seguidos por sua descrição.

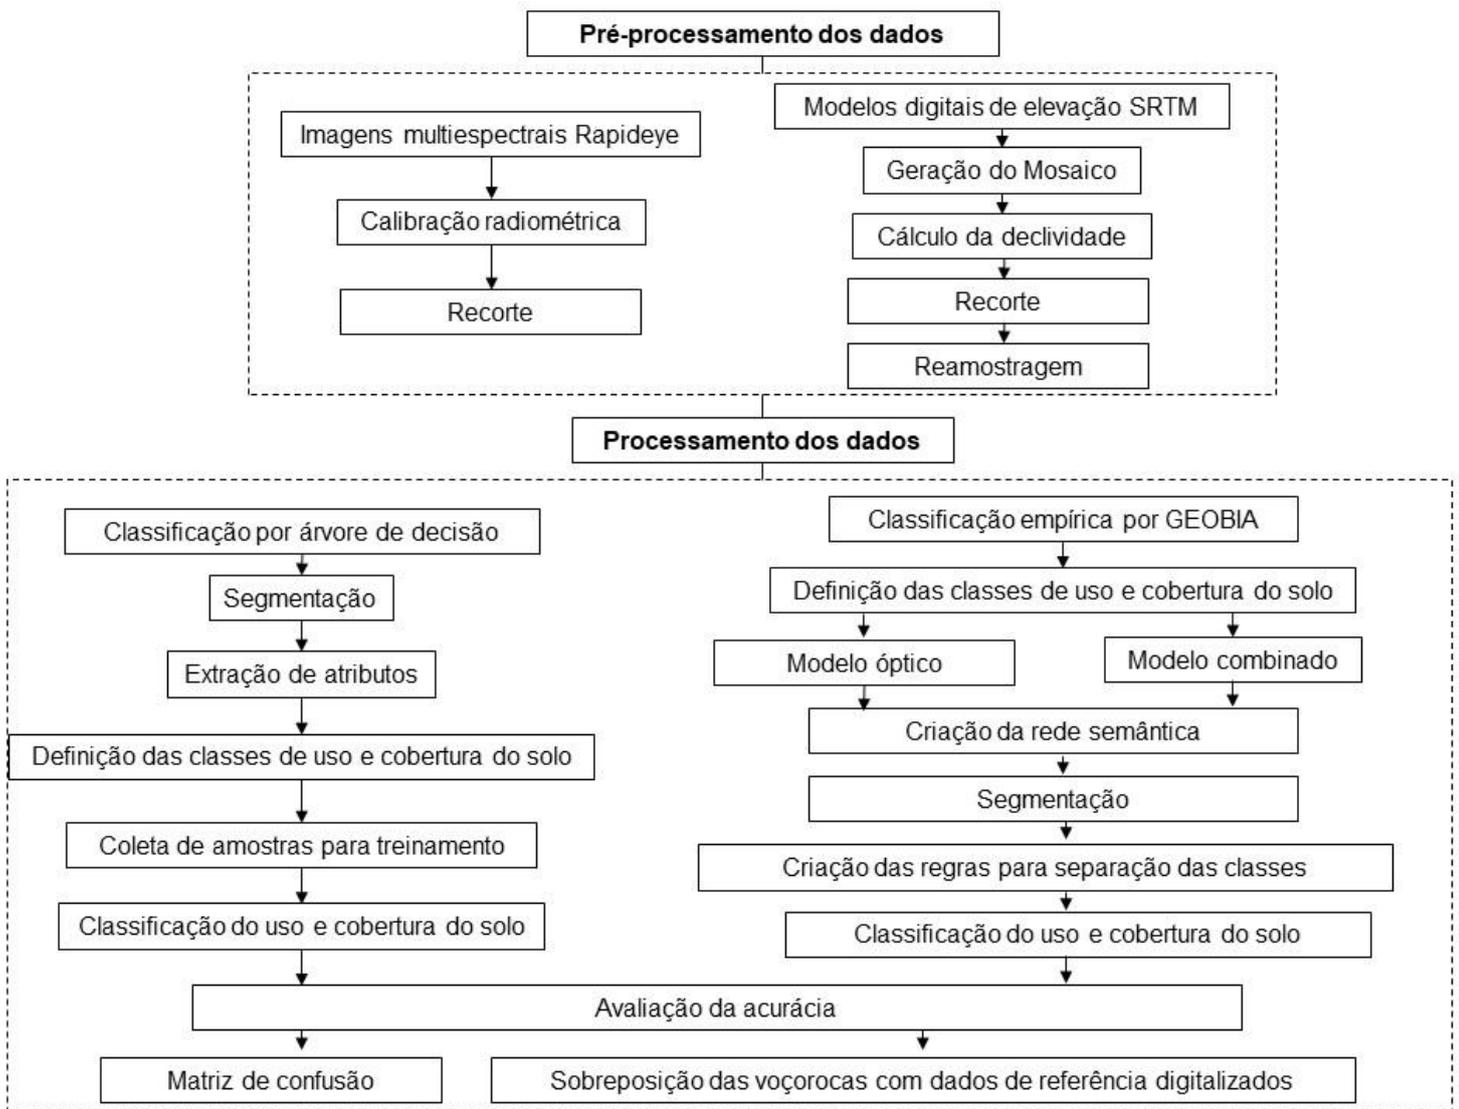


Figura 4. Fluxograma dos procedimentos metodológicos.

4.3.1 Pré-processamento dos dados

De acordo com Ponzoni et al. (2007), a reflectância é a razão entre a radiação refletida pela radiação incidente, podendo ser expressa através dos chamados Fatores de Reflectância. Devido à ausência de informações sobre a composição atmosférica nas datas de aquisição das imagens RapidEye foi realizada apenas a calibração radiométrica. Desse modo, fez-se a conversão dos números digitais das imagens RapidEye para reflectância do topo da atmosfera (TOA), a partir do complemento *Geosud Reflectance TOA*, disponível no Qgis.

O Geosud realiza a conversão a partir de dados fornecidos pelo próprio sistema sensor no momento de aquisição das imagens. Esse complemento oferece dois formatos de saída dos dados: a) reflectância (32 bits), de modo que os valores fiquem entre 0 e 1; b) mili-reflectância, no qual os valores de reflectância são multiplicados por 1000. Adotou-se nesse trabalho a saída no formato de mili-reflectância. Essa medida possibilita a codificação em 16 bits, tornando possível a redução de espaço em sua criação (Baghdadi et al., 2018). Feito isso, as imagens foram recortadas nas áreas de estudos a partir do Qgis. A Equação 9 descreve a conversão para reflectância TOA.

$$\rho_{\lambda} = \frac{\pi \cdot L_{\lambda} \cdot d^2}{ESUN_{\lambda} \cdot \cos(\theta)} \quad (9)$$

em que,

ρ_{λ} - reflectância aparente ou do topo da atmosfera (adimensional);

L_{λ} - radiância bidirecional aparente (W/ (m².sr.μm));

d - distância Terra-sol em unidades astronômicas (adimensional);

$ESUN_{\lambda}$ - irradiância solar exoatmosférica média no topo da atmosfera (W/ (m².sr.μm));

θ é o ângulo zenital solar (graus).

Em relação aos dados SRTM, inicialmente foi feito o mosaico, uma vez que a área 1 situa na divisa das duas cenas. Em seguida foi efetuado o cálculo da declividade em graus e logo após o recorte nas áreas de estudos. Visando eliminar erros de processamento no InterIMAGE, causados pela introdução de dados de

entrada com resoluções diferentes, fez-se a reamostragem de 30 m para 5 m. Todas as operações de pré-processamento dos modelos digitais de elevação foram efetuadas no Qgis.

4.3.2 Definição das classes de uso e cobertura do solo

A definição das classes de uso e cobertura do solo foi baseada na análise visual das imagens RapidEye, nas imagens do Google Earth Pro e no conhecimento da área. Assim, foram definidas 6 classes: voçorocas, pasto, campo sujo, sombras, vegetação arbórea e solo exposto. Apesar de haver algumas edificações e estradas sem pavimentação na cena, optou-se por considerar esses alvos como regiões de solo exposto, devido à alta similaridade espectral entre essas classes.

4.3.3 Classificação a partir do modelo empírico

A criação do modelo de classificação dos alvos no InterIMAGE é realizada a partir dos operadores existentes em cada nível da rede semântica, os quais podem ser divididos em “top-down” e “bottom-up”. Os operadores “top-down” realizam a partição da cena em regiões, identificando segmentos com o potencial de pertencer a cada classe de acordo com as regras criadas. Já os operadores “bottom-up” refinam as classificações produzidas na etapa “top-down”, confirmando-as ou rejeitando-as. Ao final, as hipóteses validadas se tornam instâncias de objetos (Rodrigues, 2014). A Figura 5 ilustra o processo de classificação no *software* InterIMAGE.

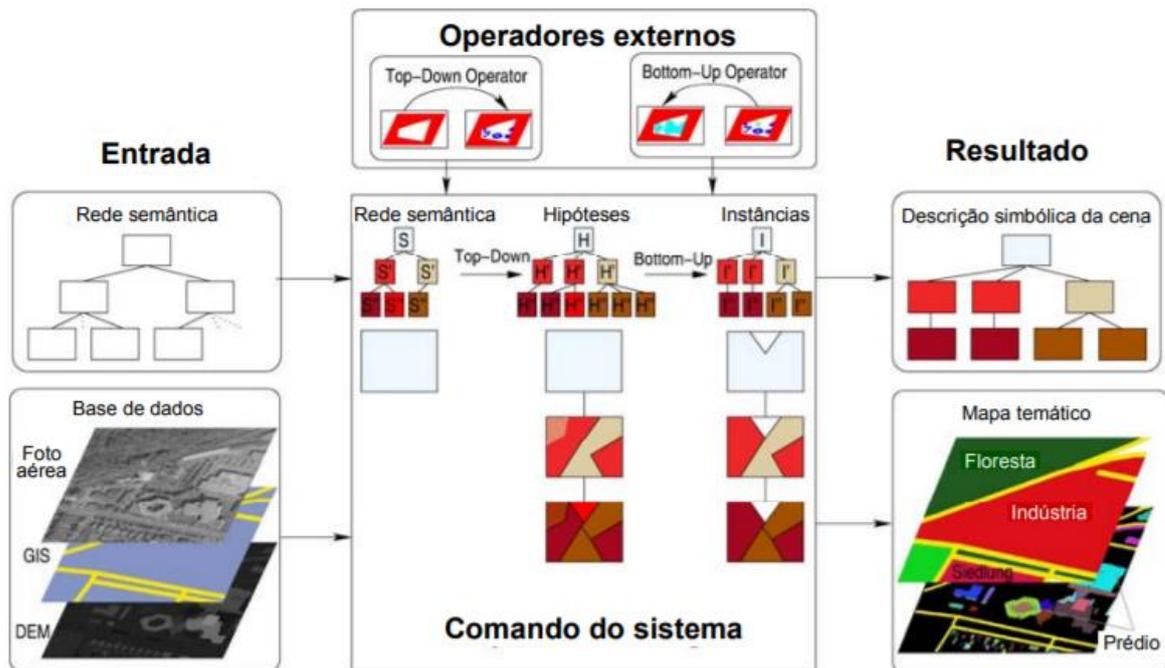


Figura 5. Processo de classificação no *software* InterIMAGE. Fonte: Pahl (2008).

O presente estudo adotou a estratégia de criar as regras de classificação utilizando apenas operadores “*top-down*”. Assim, utilizou-se nas classes de uso do solo o operador padrão *Dummy bottom-up*, o qual não cria hipóteses adicionais de classificação. Com exceção da classe campo sujo, utilizou-se o operador *TA_Batz_Segmenter* para segmentar e identificar as classes de uso e cobertura do solo. Para o campo sujo foi escolhido o operador *Dummy top-down*, o qual recebe os objetos não classificados pelas demais regras. Dessa forma, não foi necessário fornecer os pesos de entrada da segmentação nem os parâmetros descritores da classe campo sujo.

Foram criados dois modelos de classificação das voçorocas em função dos dados de entrada: a) modelo óptico, a partir das imagens RapidEye; b) modelo combinado, a partir de imagens RapidEye e dados de declividade. Dessa forma, foi possível avaliar a influência da informação altimétrica na detecção dessas feições erosivas. Os passos necessários para o mapeamento das voçorocas foram desenvolvidos na área de estudo 1. Visando analisar a transferibilidade do modelo de detecção de voçorocas foram utilizados os mesmos parâmetros e limiares na

área de estudo 2. A classificação a partir do modelo empírico adotou os seguintes procedimentos: criação da rede semântica; segmentação da imagem; criação das regras para separação das classes e avaliação da acurácia, os quais são detalhados a seguir.

- Criação da rede semântica

Adotou-se a estratégia de construir os nós da rede semântica preferencialmente em paralelo, visando diminuir o tempo de processamento. Cada nó permitiu uma segmentação independente, bem como a construção de parâmetros específicos que discriminassem cada classe. Foram desenvolvidas duas redes semânticas para cada área de estudo, uma para o modelo óptico e outra para o modelo combinado. A Figura 6 ilustra as redes semânticas criadas para a área de estudo 1.

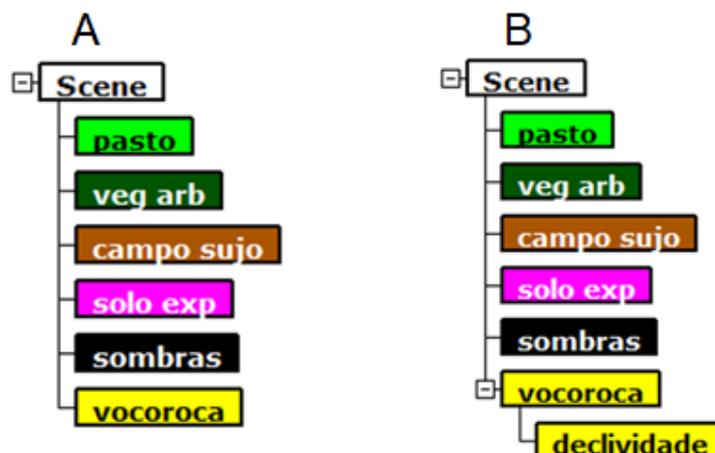


Figura 6. Redes semânticas para a área de estudo 1: A (modelo óptico) e B (modelo combinado).

A mesma estrutura hierárquica adotada na área 1 foi construída na área 2. No entanto, a área 2 possui uma vocoroca muito extensa (130 m de comprimento), a qual não foi segmentada corretamente usando o fator de escala 15 adotado na área 1. Nesse sentido, criou-se um nó adicional na rede semântica, o qual permitiu a adoção de um fator de escala maior (50). A Figura 7 apresenta as redes semânticas criadas para a área de estudo 2.

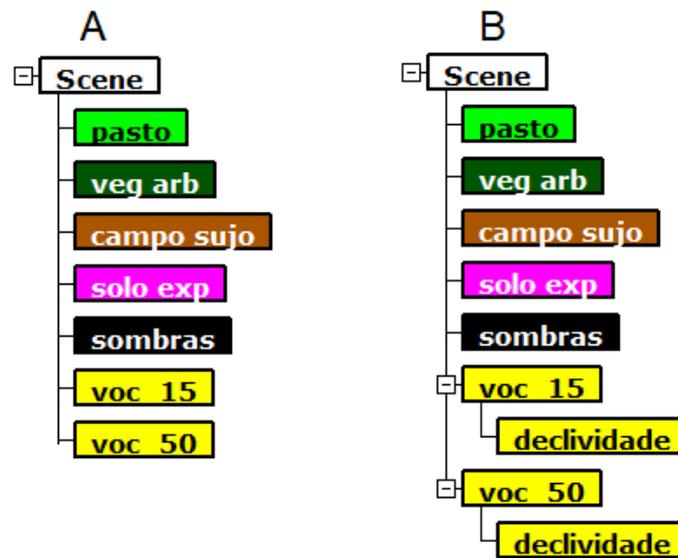


Figura 7. Redes semânticas para a área de estudo 2: A (modelo óptico) e B (modelo combinado).

- Segmentação da imagem

O algoritmo utilizado para a segmentação foi o TA_Baatz_Segmenter, que permite a segmentação independente de cada nó no InterIMAGE. Esse algoritmo requer como principais parâmetros os pesos relacionados à cor, compacidade, escala e pesos das bandas. Os valores correspondentes aos parâmetros cor e forma são complementares, de modo que a soma desses pesos deve ser igual a 1. Assim, ao se aplicar um determinado peso para a cor não é necessário atribuir o peso da forma. De forma similar, os fatores compacidade e suavidade, os quais são subdivisões do fator forma, também são complementares, sendo a suavidade obtida de forma indireta.

A escolha do melhor conjunto de pesos dos parâmetros da segmentação das voçorocas foi baseada, de forma inovadora, no cálculo do índice SEI. Esse índice é obtido a partir da comparação dos segmentos criados com os objetos de referência. Os dados de referência foram gerados pela vetorização manual das voçorocas a partir da imagem RapidEye. As voçorocas foram identificadas visualmente a partir das características de forma, tamanho, cor e tonalidade. Com o objetivo de confirmar a existência das voçorocas, utilizou-se o Google Earth Pro, o qual possui imagens com maior resolução espacial.

Foram criadas diversas combinações de pesos de entrada dos parâmetros de segmentação, gerando diferentes partições da cena. Os pesos referentes à compacidade e à cor variaram entre 0,1 e 0,9, com um intervalo de 0,2. Já o fator de escala variou entre 5 e 40, baseado em testes preliminares no *software* InterIMAGE. Cada resultado da segmentação foi exportado para o *software* Qgis 2.14.13, com o qual foi possível realizar a comparação com os dados vetorizados.

Para cada segmento candidato foi calculado a área total, bem como as áreas de interseção e de diferença com as voçorocas de referência, tornando possível o cálculo do índice SEI_i. Após calcular o SEI_i de todas os segmentos candidatos foi possível obter o índice SEI correspondente a toda cena, a partir do cálculo da média dos SEI_i. Assim, os melhores pesos de cada parâmetro foram obtidos a partir das segmentações que geraram os menores valores do SEI. A Tabela 2 apresenta o resultado dos testes de segmentação para as voçorocas.

Tabela 2. Otimização da segmentação das voçorocas na área de estudo 1.

Compacidade	Cor	Escala	Peso das bandas (1,2,3,4,5)	Número de objetos com sobreposição bilateral de 50%	Índice de segmentação (SEI)
0,5	0,5	5	1_1_1_1_1	0	1
0,5	0,5	10	1_1_1_1_1	1	0,90
0,5	0,5	15	1_1_1_1_1	1	0,90
0,5	0,5	25	1_1_1_1_1	1	0,90
0,5	0,5	40	1_1_1_1_1	1	0,90
0,1	0,9	15	1_1_1_1_1	1	0,91
0,3	0,7	15	1_1_1_1_1	2	0,82
0,7	0,3	15	1_1_1_1_1	2	0,79
0,9	0,1	15	1_1_1_1_1	1	0,90
0,7	0,3	15	0_1_1_1_1	2	0,72
0,7	0,3	15	1_0_1_1_1	3	0,71
0,7	0,3	15	1_1_0_1_1	2	0,81
0,7	0,3	15	1_1_1_0_1	2	0,82
0,7	0,3	15	1_1_1_1_0	3	0,72
0,7	0,3	15	0_1_1_0_1	2	0,82
0,7	0,3	15	0,5_1_1_0,5_1	3	0,74
0,7	0,3	15	0,5_1_1_0_1	3	0,73
0,7	0,3	15	0_1_1_0,5_1	3	0,72
0,7	0,3	15	0_1_1_0,8_1	3	0,72

Embora o menor valor referente ao índice SEI indique o melhor conjunto de pesos da segmentação, há uma generalização dos segmentos que não atingiram a regra de sobreposição bilateral de 50%. Assim, segmentos que estão próximos de atingir a regra recebem o mesmo valor dos segmentos que são muito discrepantes. Por esse motivo, a combinação referente ao índice SEI com valor 0,71 não foi escolhida, sendo selecionada a combinação com SEI de 0,72 (última linha da Tabela 2). Sendo assim, a escolha da melhor combinação de pesos de entrada baseou-se no cálculo do índice SEI, mas também na análise da forma dos objetos que não foram contemplados pela regra de correspondência.

O conjunto de pesos referentes à melhor segmentação obteve os seguintes valores: compacidade (0,7); cor (0,3); escala (15); banda azul (0); banda verde (1); banda vermelho (1); banda do vermelho limítrofe (0,8) e banda do infravermelho (1). A escolha do peso 0,3 para o parâmetro cor implica na adoção do peso 0,7 para a forma, uma vez que são complementares. Essa composição de pesos entre cor e forma se justifica pela mistura espectral das voçorocas, de modo que o aumento do peso relativo à forma diminui o erro na criação dos segmentos. Já em relação às subdivisões do parâmetro forma, foi atribuído maior peso para o fator compacidade (0,7), em detrimento da suavidade (0,3), pois as voçorocas apresentam pequena extensão em relação à área total da cena e possuem limites abruptos.

Os parâmetros cor e forma são pouco discutidos na literatura relacionada com a detecção de voçorocas, embora os pesos da segmentação sejam de extrema importância no processo criação dos objetos (Liu et al., 2016). Wang et al. (2014), ao detectar voçorocas individuais, também atribuíram altos pesos para a forma (0,9) e compacidade (0,8). Já Scholte-Albers (2015), ao mapear voçorocas aluviais na Espanha, atribuiu o peso 0,6 para o fator forma e 0,4 para compacidade.

Em relação aos pesos das bandas multiespectrais, Wang et al. (2014), também atribuíram peso mínimo à banda azul para detecção de voçorocas na China. Segundo os autores essa região espectral contribui com pouca informação sobre as feições erosivas, além de ser mais afetada pelo espalhamento atmosférico. As demais bandas contribuem de forma mais efetiva, e por isso receberam pesos maiores.

Para as demais classes de uso e cobertura do solo optou-se por realizar a avaliação visual da segmentação por dois motivos: 1) essas classes apresentam objetos com tamanhos e formas variadas, tornando difícil estabelecer um padrão de segmentação utilizando apenas um nó na rede semântica; 2) os comportamentos espectrais dessas classes já foram amplamente estudados pela literatura, sendo possível realizar mapeamento utilizando apenas informações espectrais. A Tabela 3 apresenta os valores dos parâmetros de segmentação de cada classe. Conforme citado anteriormente não foi necessário atribuir os pesos da segmentação para a classe campo sujo devido ao algoritmo utilizado para essa classe.

Tabela 3. Parâmetros de segmentação para o pasto, sombra, vegetação arbórea e solo exposto.

Classes	Compacidade	Cor	Escala	Pesos das bandas
Pasto	0,7	0,9	20	1,1,1,1,1
Sombras	0,9	0,9	8	1,1,1,1,1
Vegetação arbórea	0,7	0,9	10	1,1,1,1,1
Solo exposto	0,9	0,9	10	1,1,1,1,1

- Criação das regras para separação das classes

A escolha dos melhores parâmetros para classificação das voçorocas se deu a partir da revisão da literatura, dos testes no InterIMAGE, e do auxílio do complemento de mineração de dados Geodma, disponível no *software* Terraview. A partir do Geodma foi possível extrair automaticamente uma grande variedade de atributos espaciais, espectrais, geométricos e texturais para todos os segmentos da cena. Esses dados foram armazenados nas tabelas de atributos do Terraview, tornando mais fácil a interpretação dos atributos mais relevantes para identificação das voçorocas. A Tabela 4 apresenta a descrição dos parâmetros utilizados para detectar as voçorocas.

Tabela 4. Descrição dos parâmetros do modelo empírico para detectar voçorocas.

Atributo	Descrição
Média	Valor médio da reflectância de uma banda espectral para cada objeto
Amplitude	Representa a diferença entre o maior e o menor valor do pixel do objeto para uma determinada banda
Comprimento/largura	Cálculo da razão entre o comprimento e a largura do objeto
Compacidade	Retorna a compacidade do objeto, a qual é expressa pela seguinte equação: $\text{Compacidade} = \frac{P/A}{\sqrt{A}}$ <p>sendo que, P corresponde ao perímetro do objeto e A a área</p>

Em geral, as voçorocas apresentam altos valores de reflectância em todas as 5 bandas do RapidEye. Visando separar as regiões densamente cobertas por vegetação, adotou-se o limiar mínimo de 120 para a banda do vermelho (b3), uma vez que há forte absorção da radiação pela vegetação nesse intervalo. Já as regiões de solo exposto possuem uma resposta espectral similar às voçorocas. No entanto, devido à mistura espectral com outras classes, as voçorocas apresentam valores de reflectância mais baixos que o solo exposto na região do infravermelho (b5). Por esse motivo, adotou-se o limiar máximo de 250 para a banda 5 visando minimizar a confusão entre as voçorocas e as regiões de solo exposto.

Devido à forma mais alongada das voçorocas adotou-se valores acima de 0,5 para a relação comprimento/largura. Já a compacidade acima de 0,0028 fez com que os objetos grandes e com formas mais regulares fossem excluídos da classificação, diminuindo o número de falsos positivos. O limiar mínimo 75 para a amplitude da banda 5 auxiliou o mapeamento dessas feições erosivas devido à informação textural. A partir dos testes realizados foi estabelecido o valor de 8° de declividade como limiar mínimo na extração das voçorocas. A Tabela 5 sintetiza os limiares dos parâmetros escolhidos para a detecção de voçorocas.

Tabela 5. Parâmetros utilizados para detectar as voçorocas no modelo empírico.

Média banda 3	Média banda 5	Amplitude Banda 5	Comprimento/largura	Compacidade	Declividade
>120	<250	>75	>0,5	>0,0028	>8°

Os parâmetros dos modelos das demais classes de uso e cobertura do solo foram obtidos por meio da revisão da literatura e dos testes no InterIMAGE. A Tabela 6 apresenta a descrição dos atributos utilizados para a distinção das classes solo exposto, sombras, pasto e vegetação arbórea nas duas áreas de estudos.

Tabela 6. Descrição dos parâmetros do modelo empírico para as demais classes.

Atributo	Descrição
NDVI _{RE}	Índice de vegetação por diferença normalizada da região do red-edge (Gitelson e Merzlyak, 1994) : $NDVI_{RE} = \frac{(R_{NIR} - R_{RED-EDGE})}{(R_{NIR} + R_{RED-EDGE})}$
Brilho	Representa o brilho de um objeto
Índice sombra	Retorna a média dos valores de reflectância do objeto para as 5 bandas: $\text{Índice sombra} = \frac{(R_{b1} + R_{b2} + R_{b3} + R_{b4} + R_{b5})}{5}$

Para a classe campo sujo utilizou-se o algoritmo Dummy TopDown, o qual não necessita de parâmetros de segmentação e de classificação, uma vez que são atribuídos a essa classe todos os objetos não classificados. As regras e limiares adotados para cada classe são apresentados na Tabela 7.

Tabela 7. Regras do modelo empírico para as demais classes.

Classes	Área 1	Área 2
Pasto	NDVI _{RE} > 0,32; brilho > 120	NDVI _{RE} > 0,25; brilho > 130
Sombras	Índice sombra < 85	Índice sombra < 85
Vegetação arbórea	NDVI _{RE} > 0,42; brilho < 120; brilho > 80	NDVI _{RE} > 0,32; brilho < 130; brilho > 85
Solo exposto	NDVI _{RE} < 0,28	NDVI _{RE} < 0,2

4.3.4 Classificação por árvore de decisão

A classificação pelo método da árvore de decisão foi realizada a partir do aplicativo Geographic Data Mining Analyst (Geodma), instalado no *software* Terraview. Esse aplicativo utiliza o algoritmo C4.5 (Quinlan, 1993), que é um tradicional algoritmo de árvore de decisão, com eficácia comprovada pela literatura. O algoritmo C4.5 cria árvores de decisão de modo que cada nó da árvore corresponde a um atributo e cada arco corresponde a uma faixa de valor do atributo (Ribeiro e Fonseca, 2013). A classificação é realizada a partir de um conjunto de dados de treinamento, de modo que a cada nó, o algoritmo escolhe um atributo que melhor particione o conjunto de amostras em subconjuntos homogêneos. O critério de particionamento é o ganho de informação obtida na escolha do atributo para subdivisão (Quinlan, 1993).

O primeiro passo para realizar a classificação é a segmentação da imagem, a qual necessita dos pesos para a cor, compacidade e escala. Para isso, utilizou-se os mesmos pesos obtidos na segmentação das voçorocas no modelo empírico, atribuindo peso 30 para cor e 70 para compacidade. No entanto, o fator de escala precisou ser alterado para 8, pois os valores obtidos pelo Gedma divergem daqueles obtidos com o *software* InterIMAGE.

Realizada a segmentação da imagem foi possível extrair os atributos de todos os segmentos automaticamente. Esses atributos estão relacionados com parâmetros

espectrais, geométricos e texturais que cada objeto possui. Posteriormente foi realizada a etapa de treinamento do algoritmo, a partir da coleta de amostras para cada classe. Ao final, foi realizada a classificação a partir da seleção automática dos parâmetros que melhor descrevessem cada classe. A Figura 8 ilustra o modelo gerado a partir da árvore de decisão resultante na área 1.

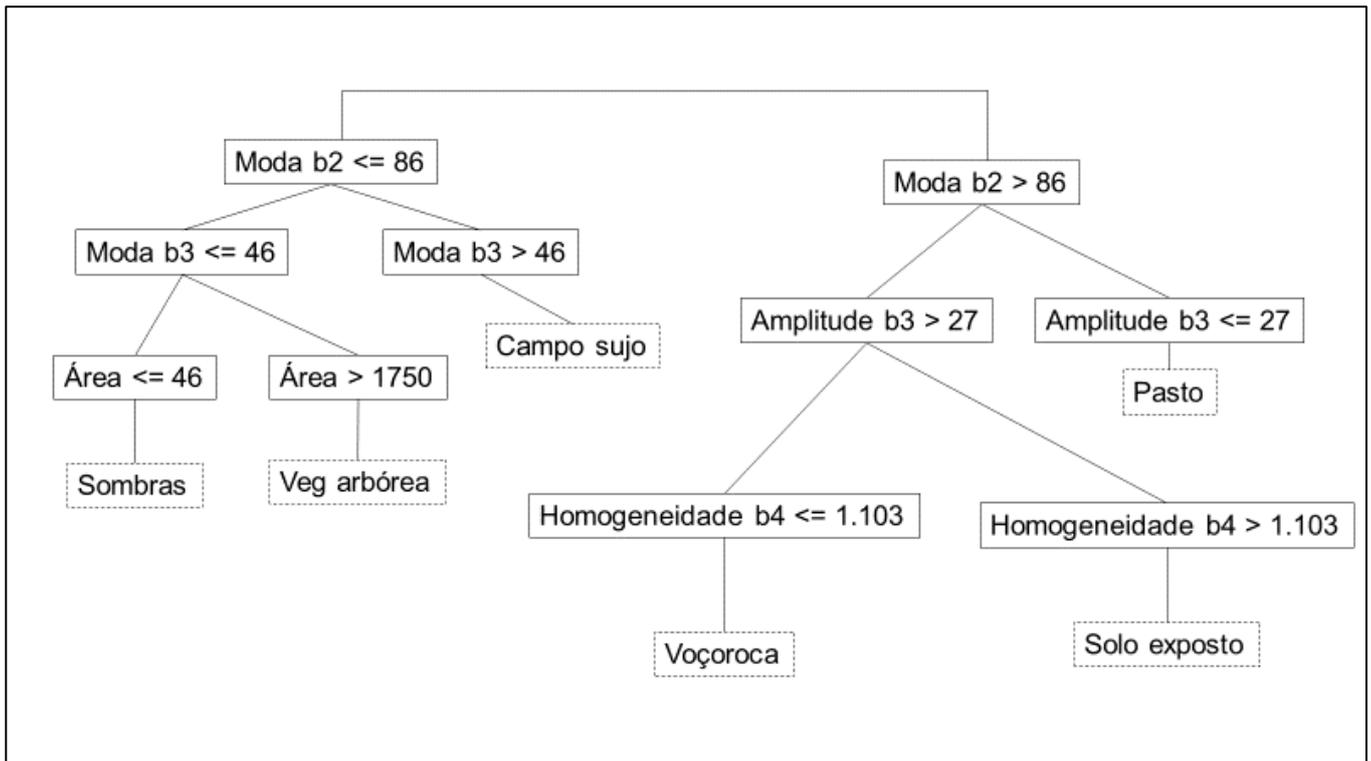


Figura 8. Modelo gerado pelo algoritmo de árvore de decisão para a área 1.

A classificação das voçorocas por árvore de decisão inicia com o limiar mínimo 86 para a moda da banda 2. Essa variável seleciona os valores espectrais mais frequentes dentro do segmento. Dessa forma, separou-se os objetos com maior resposta espectral dos demais objetos mais escuros. Em seguida, foram utilizados dois critérios texturais para detectar as voçorocas: amplitude e homogeneidade. As duas variáveis são antagônicas, de modo que a amplitude calcula a variação entre a menor e a maior resposta espectral da banda e a homogeneidade assume valores maiores para as menores diferenças de textura.

Para realizar a classificação a partir da árvore de decisão na área de estudo 2 foram mantidos os pesos referentes a cor e a compacidade na etapa da segmentação. No entanto o fator de escala foi alterado para 20, em função da maior extensão das voçorocas nessa área. A Figura 9 ilustra o modelo gerado pelo algoritmo C4.5 na área 2.

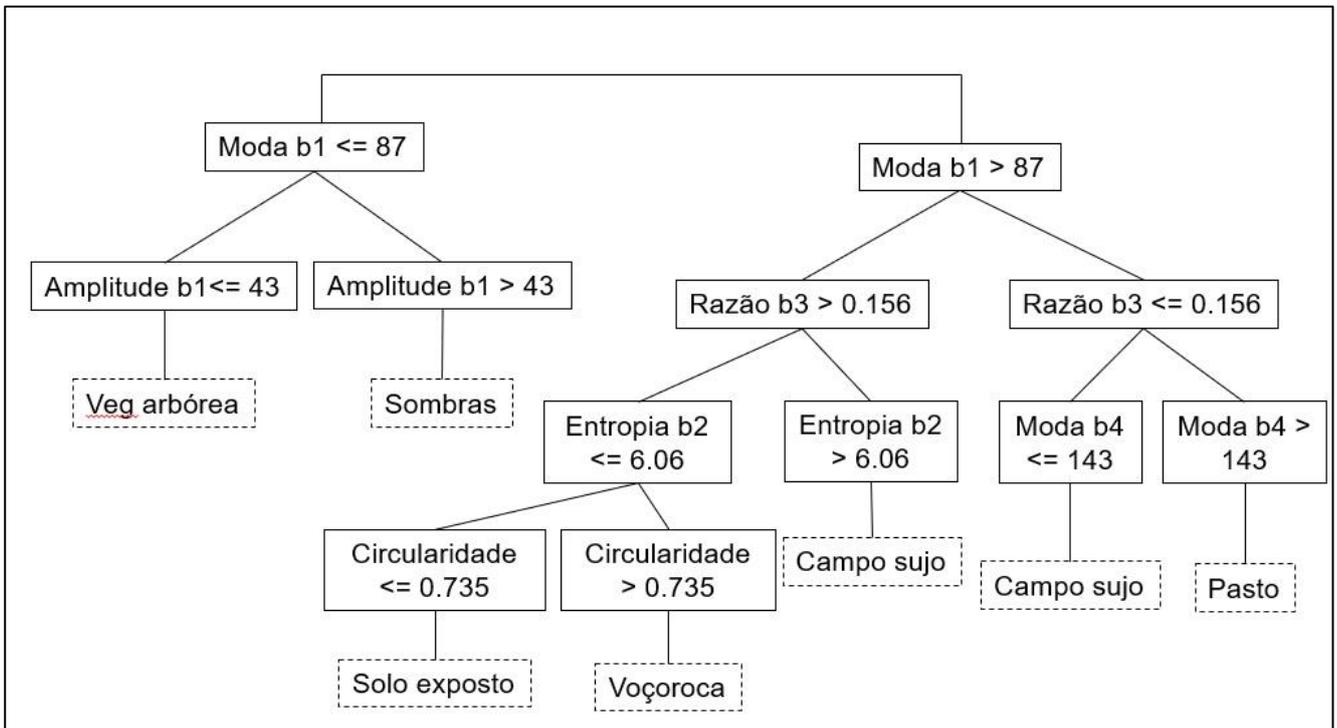


Figura 9. Modelo gerado pelo algoritmo de árvore de decisão para a área 2.

A detecção da classe voçoroca inicia pela separação de altas respostas espectrais para a banda 1. Em seguida foi utilizado o parâmetro razão da banda 3, que representa o quanto a respectiva banda contribui para o brilho total do objeto. Logo após é introduzida a variável entropia da banda 2, sendo um critério que avalia a textura do objeto, uma vez que representa a frequência dos valores para essa banda. Por fim, é utilizado o critério de circularidade mais elevada para separação dos segmentos de solo exposto. A Tabela 8 apresenta a descrição dos parâmetros utilizados nos modelos de árvore de decisão.

Tabela 8. Descrição dos parâmetros gerados pela árvore de decisão.

Atributo	Descrição
Moda	Representa o valor mais frequente dentro de um conjunto.
Amplitude	Representa a diferença entre o maior e o menor valor do pixel do objeto para uma determinada banda.
Homogeneidade	Representa a variação textural de um objeto, assumindo valores maiores para as menores diferenças de textura.
Razão	Representa a contribuição de uma camada para o brilho total de um objeto.
Entropia	Medida estatística de aleatoriedade que pode ser utilizada para descrever atributos texturais.
Circularidade	Representa o quão próximo o objeto está de um círculo.
Área	Representa a área real do objeto em metros.

4.3.5 Avaliação da acurácia

A avaliação da acurácia foi realizada de duas formas: a) avaliação por meio da matriz de confusão; b) sobreposição com dados de referência vetorizados manualmente. É importante destacar que não houve diferenciação nesse estudo entre voçorocas e ravinas para realizar o mapeamento, seguindo o significado mais amplo do termo voçoroca permanente utilizado internacionalmente. Porém, os sulcos não fazem parte do escopo do presente trabalho, uma vez que apresentam menor potencial de degradação.

A avaliação por meio da matriz de confusão foi possível avaliar o desempenho dos modelos por meio dos seguintes coeficientes de concordância: acurácia do produtor, acurácia do usuário, índice de acurácia global e índice Kappa. Para isso, foram gerados 50 pontos aleatórios estratificados por classe, conforme definido por Congalton e Green (1999). A criação dos pontos foi realizada no *software* Terraview, sendo posteriormente exportados para o Qgis para identificação das classes verdadeiras a partir da visualização da imagem RapidEye e auxílio do Google Earth Pro.

A matriz de confusão e os respectivos índices de acurácia foram gerados a partir do complemento *Semi-automatic classification Plugin* (SCP), disponibilizado

dentro do Qgis. Esse complemento realiza o cálculo da acurácia em função do número de pixels. Assim, o número total de pixels na área 1 foi de 591 e na área 2 de 536, uma vez que a maioria dos pontos englobava 2 pixels na imagem.

Segundo Vrieling et al. (2007), a utilização dos tradicionais índices de acurácia Kappa e Global pode mascarar a validação em trabalhos que detectam voçorocas, uma vez que, as regiões cobertas por essas feições são apenas uma pequena fração da imagem. Uma das medidas mais frequentemente utilizadas para avaliar a performance de um algoritmo em situação de desequilíbrio das classes é o F-measure. Essa medida fornece uma melhor descrição sobre o quanto o classificador aprendeu sobre uma classe, quando comparado com a acurácia global. Tal fato está relacionado com a utilização conjunta dos falsos positivos e os falsos negativos, enquanto a acurácia global considera apenas os falsos positivos (Davis e Goadrich, 2006).

Visando avaliar a acurácia da classificação das voçorocas em relação à totalidade do objeto foi realizada a sobreposição dos segmentos classificados com os dados de referência vetorizados manualmente. Dessa forma, foi possível obter a acurácia do usuário, a acurácia do produtor e o índice F-measure. A acurácia do produtor indica o quão bem os pixels de uma classe conhecida no terreno foram classificados. Já a acurácia do usuário indica a probabilidade de um pixel classificado represente realmente aquela categoria no terreno.

O índice F-measure é extraído a partir dos valores de acurácia do produtor e acurácia do usuário para a classe voçoroca. Essa medida quantifica a sobreposição entre os dados reais e os estimados, variando entre 0 (ausência de sobreposição) e 1 (sobreposição completa) (Labatut e Cherifi, 2011). A Equação 10 apresenta a fórmula F-measure:

$$F\text{-measure} = \frac{2 \cdot AP \cdot AU}{AP + AU} \quad (10)$$

em que,

AP - acurácia do produtor;
AU – acurácia do usuário.

5 RESULTADOS E DISCUSSÃO

5.1 Área de estudo 1

5.1.1 Classificação das voçorocas a partir do modelo óptico

O modelo óptico gerou 8 segmentos classificados como voçorocas, dos quais 3 foram falsos positivos. Desse modo, 5 voçorocas foram identificadas classificadas corretamente e 3 segmentos apresentaram confusão com outras classes, principalmente o solo exposto. A Figura 10 ilustra o resultado da classificação utilizando apenas imagens RapidEye como dados de entrada do modelo.

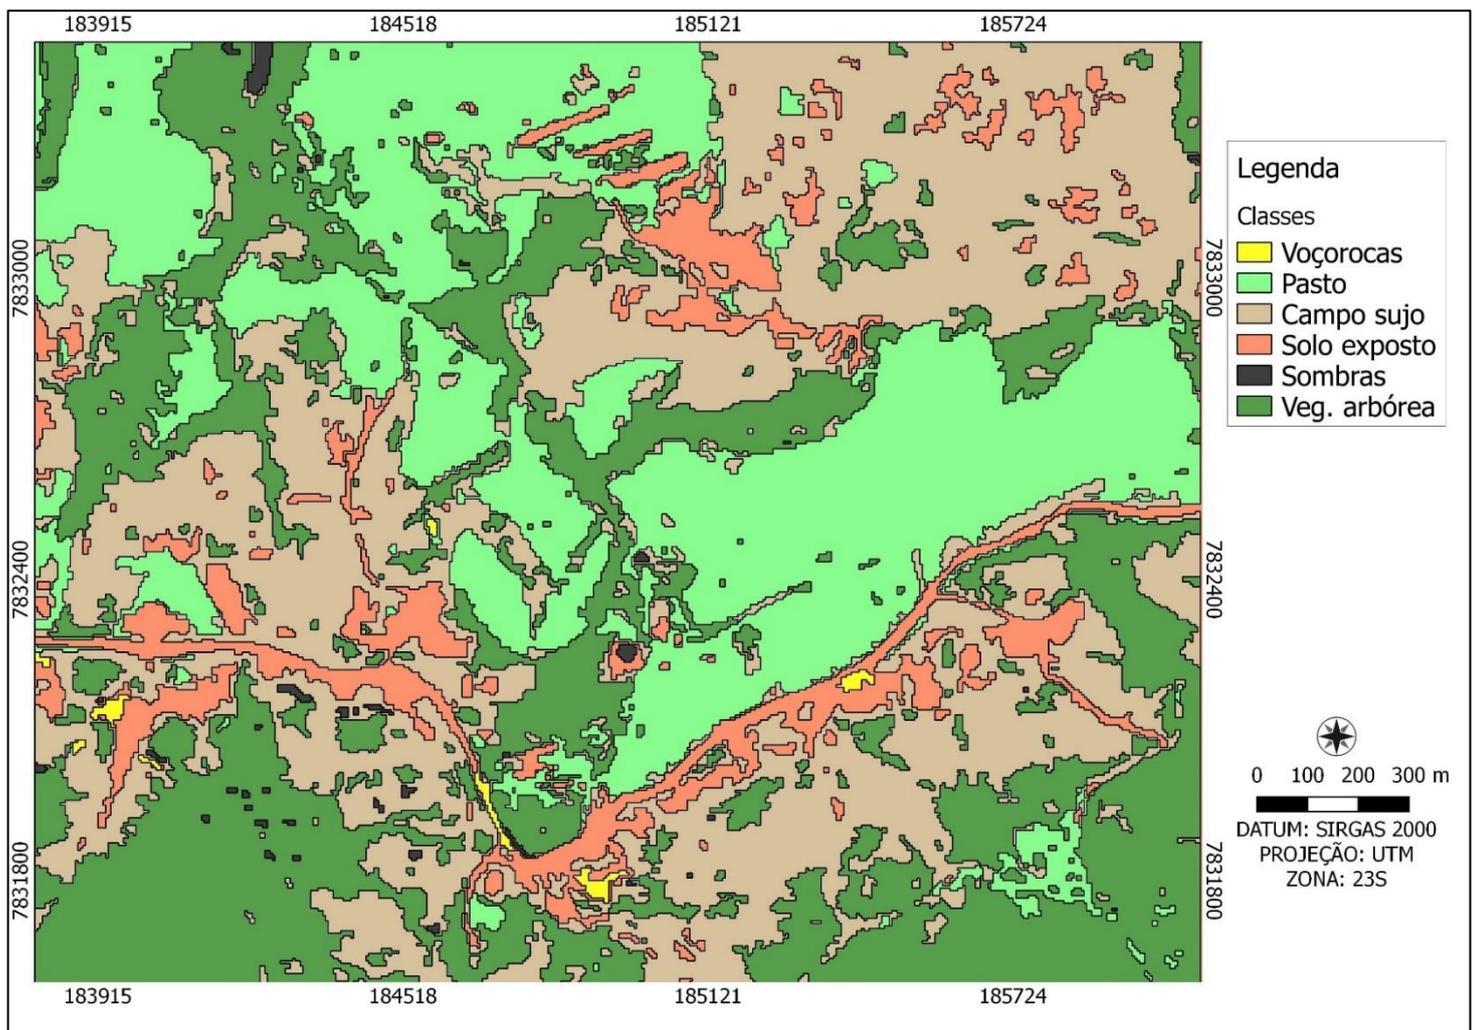


Figura 10. Classificação do uso e cobertura do solo a partir do modelo óptico na área 1.

A Figura 11 apresenta apenas o resultado da classificação das voçorocas, para maior detalhamento do mapeamento. Os segmentos amarelos representam as regiões corretamente classificadas como voçorocas. As regiões em azul correspondem aos falsos negativos, ou seja, voçorocas, ou partes de voçorocas, que não foram detectadas. Já as regiões em vermelho representam os falsos positivos, indicando as regiões que foram classificadas de maneira incorreta como voçoroca.

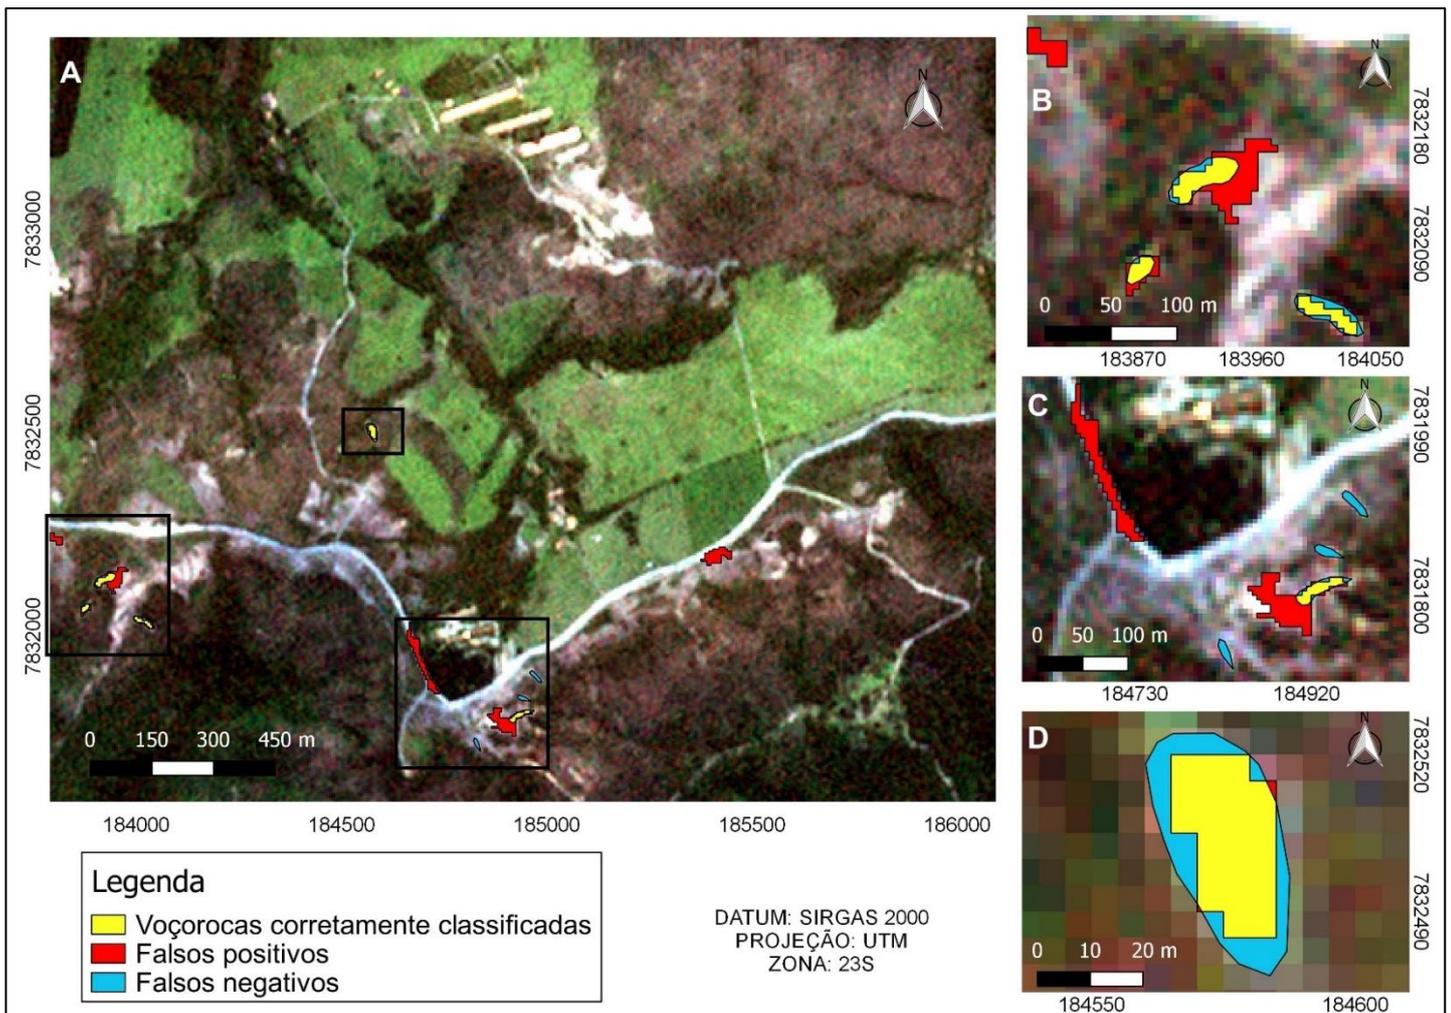


Figura 11. Detalhamento da classificação das voçorocas a partir do modelo óptico na área 1.

Devido a pequena porção do terreno ocupada pelas voçorocas (Figura 11A), pode-se considerar o resultado do modelo óptico satisfatório. A Figura 11D, por exemplo, ilustra um segmento corretamente classificado como voçoroca, apresentando apenas erros de classificação nas bordas. A correta detecção dessas

feições erosivas a partir de imagens RapidEye pode ser atribuída ao emprego do índice SEI na segmentação da cena. Assim, ao permitir a criação de objetos com geometria similar às voçorocas, foi possível extrair as características intrínsecas a esse alvo.

Por outro lado, a cena apresenta muitos alvos com características espectrais e geométricas similares às voçorocas, resultando na criação de muitos falsos positivos. As Figuras 11B e 11C ilustram exemplos de segmentos que, apesar de possuir áreas corretamente classificadas como voçorocas, apresentam discrepâncias com os limites das voçorocas no campo. Tal fato leva a uma superestimação da área realmente ocupada pelos processos erosivos avançados.

As voçorocas que não foram detectadas pelo modelo óptico são ilustradas em azul na Figura 11C. Essas feições erosivas possuem uma extensão menor em relação às demais voçorocas, apresentando largura inferior a 10 m. De acordo com a classificação proposta por Furlani (1980) as voçorocas com menos de 10 m de largura são consideradas pequenas, uma vez que voçorocas grandes podem atingir mais de 50 m de largura e 500 m de comprimento. A Figura 12 apresenta a imagem real de uma voçoroca pequena que não foi detectada.



Figura 12. Imagem de uma voçoroca pequena na área 1.

A limitação apresentada pelo modelo óptico pode estar relacionada com a resolução espacial das imagens RapidEye (5 m), a qual não permitiu identificar as voçorocas menores. Mararakanye e Nethengwe (2012), ao mapear voçorocas na Província Limpopo, África do Sul, também relataram dificuldades para extrair voçorocas com menos de 10 m de largura ao utilizar imagens SPOT 5 (5 metros de resolução espacial) como dado de entrada da GEOBIA.

Para contornar essa limitação alguns autores (Shruthi et al., 2011; D'Oleire-Oltmanns, 2014; Wang et al., 2014) optaram por usar imagens com alta resolução espacial, tornando possível a detecção dessas feições erosivas mais facilmente. No entanto, Wang et al. (2016) afirmam que, mesmo utilizando imagens de alta resolução espacial Pleiades 1-A (0,7 m), não foi possível realizar uma análise mais detalhada de voçorocas individuais. Dessa forma, os autores sugerem a utilização conjunta de diferentes fontes de dados, como imagens adquiridas por Aeronave Remotamente Pilotada - RPA, bem como diferentes escalas para auxiliar no conhecimento do processo de erosão.

Liu et al. (2016) afirmam que a utilização de RPA para o mapeamento de voçorocas pode apresentar certas dificuldades em locais com maior declividade, devido ao ângulo de aquisição da informação. Nessa situação, os autores recomendam a aquisição de imagens oblíquas, ao invés da tradicional aquisição vertical de imagens para superar esse problema.

5.1.2 Classificação das voçorocas a partir do modelo combinado

A principal melhoria obtida com a introdução da declividade no modelo foi a diminuição das regiões classificadas incorretamente como voçorocas. Tal resultado é relevante pois a cena é heterogênea, possuindo muitos alvos que visualmente podem ser confundidos com as feições erosivas. A Figura 13 apresenta o resultado da classificação a partir do modelo combinado para todas as classes.

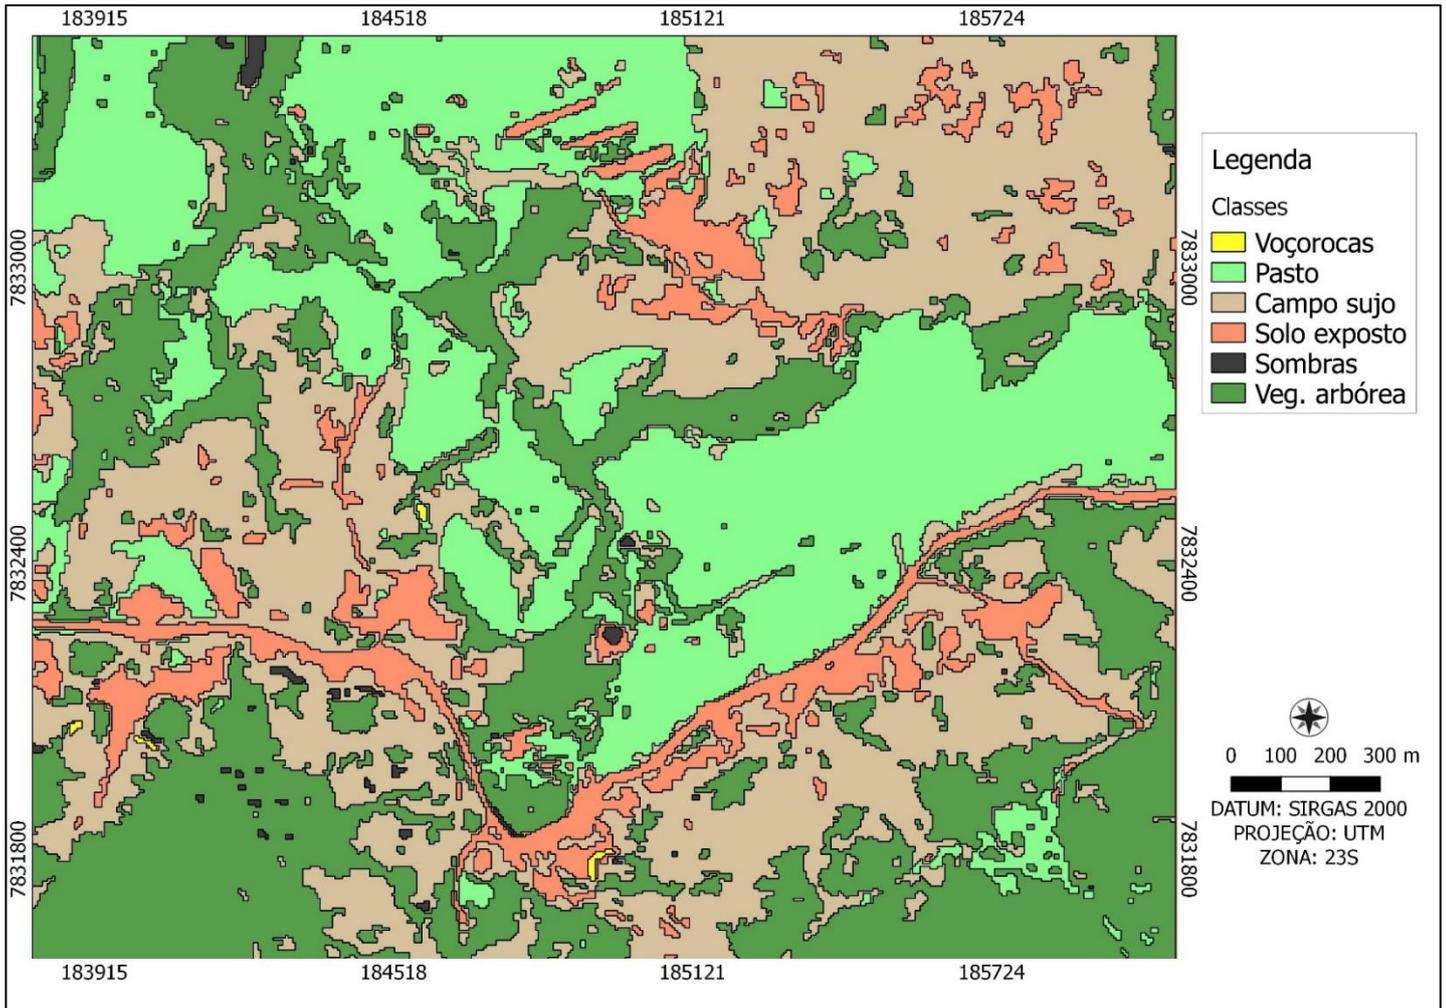


Figura 13. Classificação do uso e cobertura do solo a partir do modelo combinado na área 1.

A partir dos testes realizados foi estabelecido o valor de 8° de declividade como limiar mínimo na extração das voçorocas. Esse valor está próximo do limiar mínimo de 5° utilizado por Shruthi et al. (2012) para identificar locais com possibilidade de voçorocas. Em contrapartida, Eustace et al. (2009), em seus estudos na costa leste da Austrália, estabeleceram o limiar mínimo de 15° para detecção de voçorocas por GEOBIA. Essa diferença entre os valores mínimos de declividade se justifica pela morfologia de cada região bem como a utilização de modelos digitais de elevação com diferentes resoluções espaciais. Enquanto Eustace et al. (2009) utilizaram o sensor LIDAR, com 0.5 m de resolução, o presente estudo utilizou dados SRTM, com 30 m de resolução. A Figura 14 apresenta os detalhes da detecção das voçorocas a partir do modelo combinado.

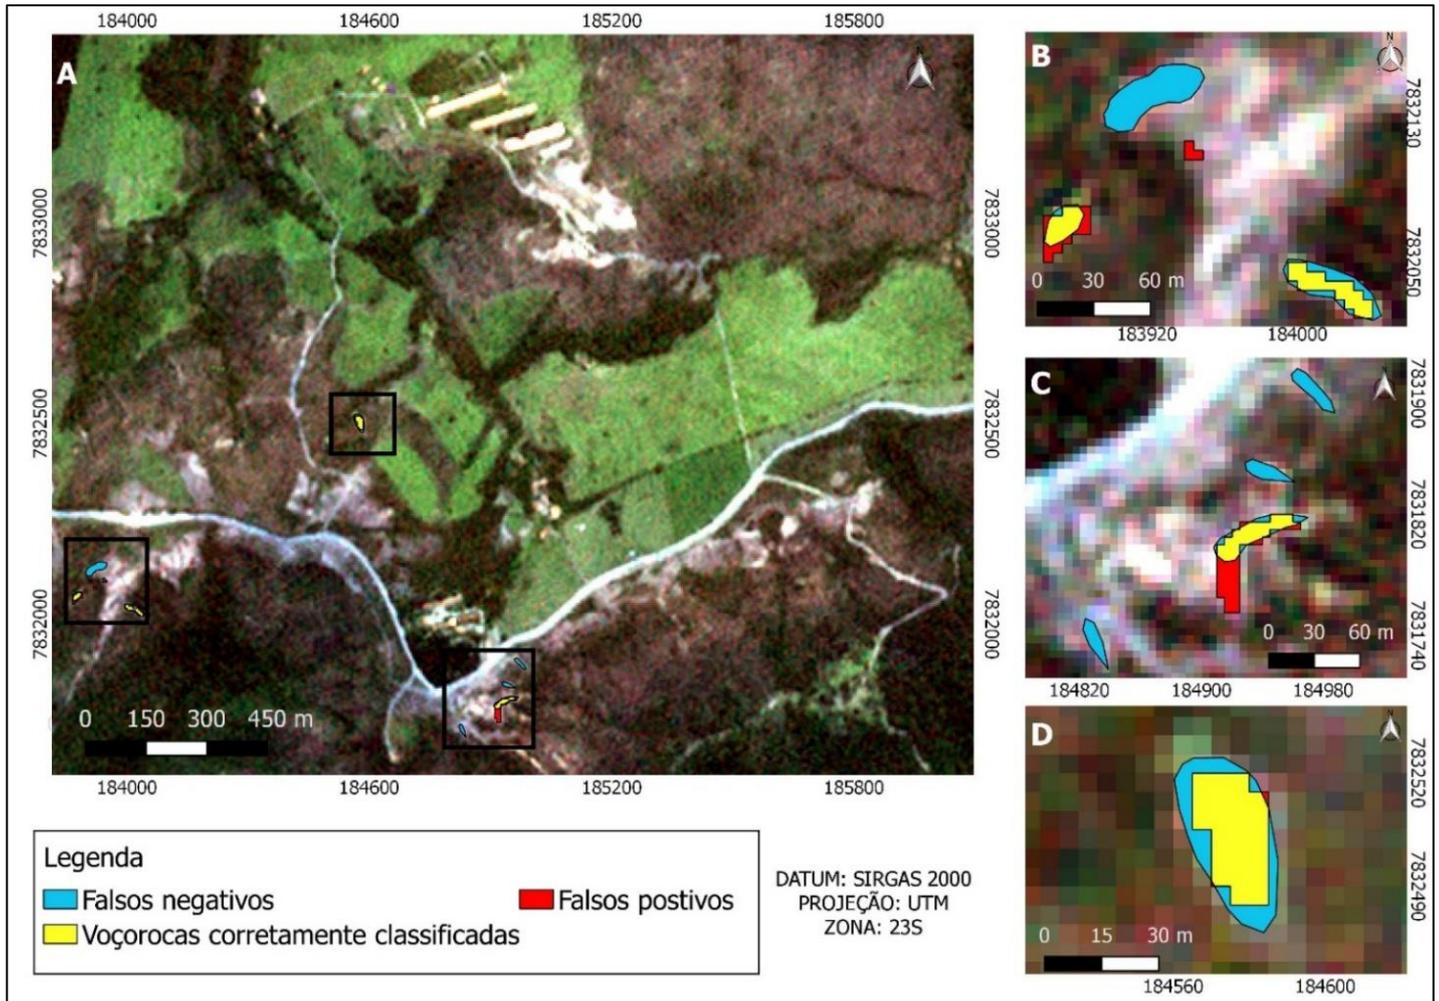


Figura 14. Detalhamento da classificação das voçorocas a partir do modelo combinado na área 1.

É possível verificar na Figura 14B que uma voçoroca que havia sido detectada anteriormente pelo modelo óptico não foi detectada pelo modelo combinado, aumentando o número de falsos negativos. Conforme citado anteriormente, esse erro pode estar associado à baixa resolução do MDE utilizado no modelo combinado. Apesar disso, é possível verificar a diminuição dos falsos positivos no modelo combinado, tanto em relação às imperfeições dos locais com voçorocas quanto a regiões em que não haviam essas feições.

5.1.3 Classificação das voçorocas por árvore de decisão

Em comparação com os modelos empíricos o mapa gerado pelo algoritmo de árvore de decisão gerou maior confusão em todas as classes de uso e cobertura do solo. A classe voçoroca apresentou 72 segmentos que foram classificados

incorretamente como voçorocas e apenas 3 classificados de forma correta. O mapa de uso e cobertura do solo por árvore de decisão é ilustrado na Figura 15.

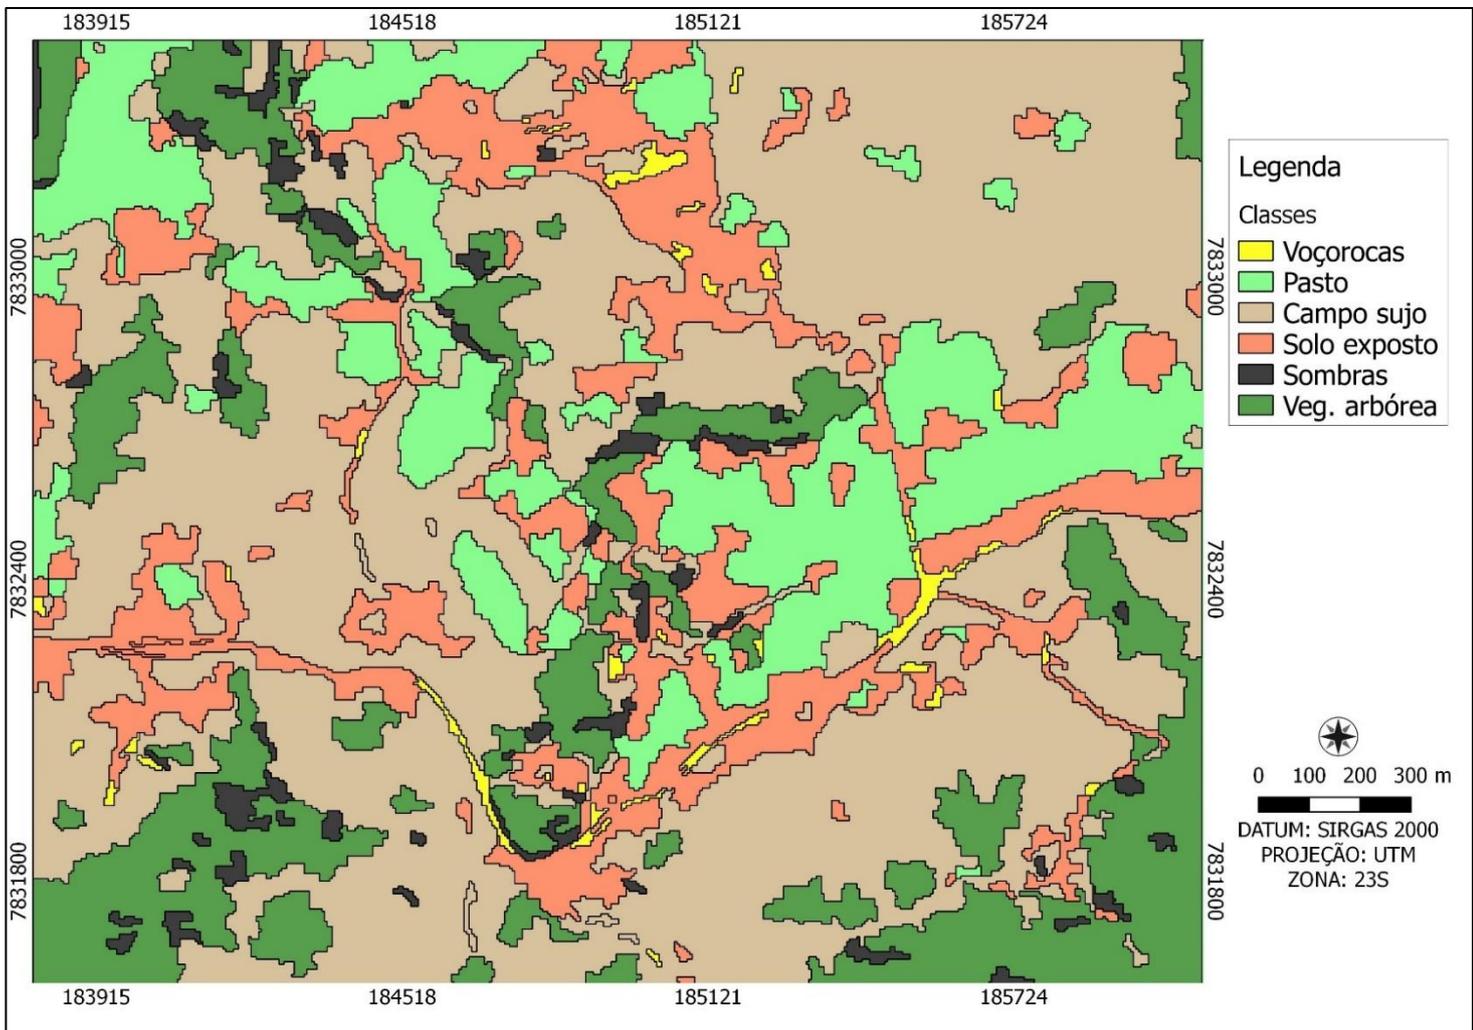


Figura 15. Classificação do uso e cobertura do solo a partir da árvore de decisão na área 1.

Os detalhes do mapeamento das voçorocas podem ser visualizados na Figura 16. É possível notar o grande número de segmentos falsos positivos a partir da Figura 16A. Além disso, nota-se 5 segmentos falsos negativos nas Figuras 16B e 16C, demonstrando a fragilidade do modelo em detectar até voçorocas mais extensas. A Figura 16D apresenta uma voçoroca que foi corretamente classificada, assim como no modelo empírico.

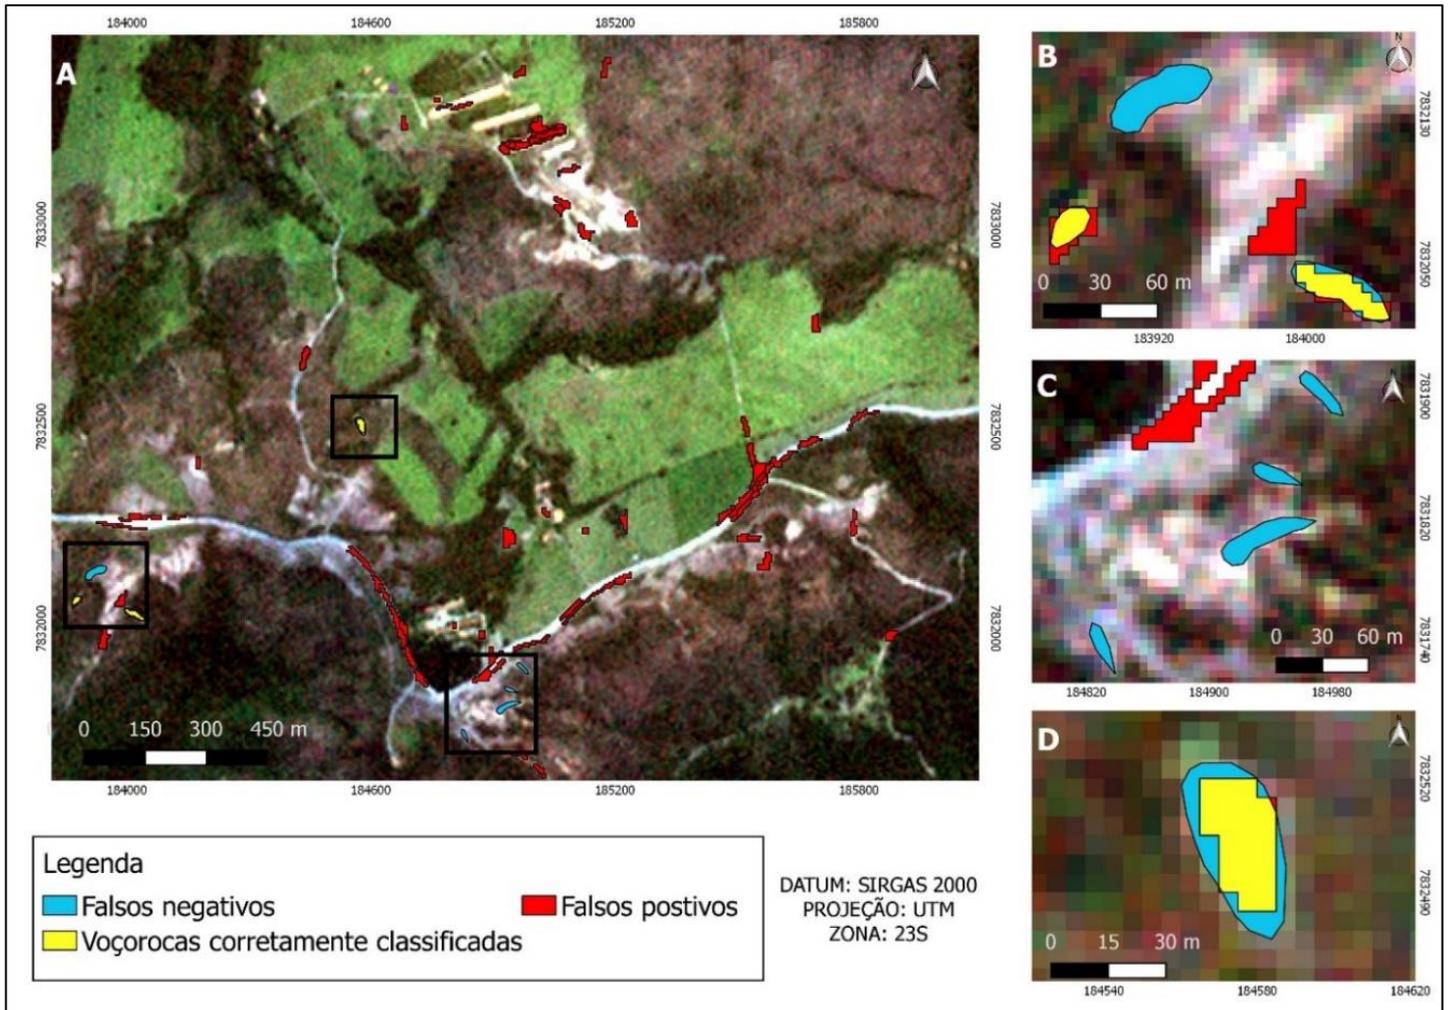


Figura 16. Detalhamento da classificação das voçorocas a partir do algoritmo de árvore de decisão na área 1.

5.1.4 Avaliação da acurácia

Inicialmente foi realizada a avaliação da acurácia por meio da matriz de confusão para cada mapa gerado. A Tabela 9 representa a matriz de confusão criada a partir do modelo óptico empírico, de modo que as colunas representam os dados de referência e as linhas o resultado da classificação.

Tabela 9. Matriz de confusão criada a partir do modelo óptico na área 1.

Classes	Veg arbórea	Pasto	Campo sujo	Solo exposto	Voçoroca	Sombra	Total	Acurácia do usuário %
Veg arbórea	174	1	4	1	0	23	203	85,71
Pasto	16	134	2	18	1	0	171	78,36
Campo sujo	17	8	46	17	1	0	89	51,68
Solo exposto	0	0	3	105	0	0	108	97,22
Voçoroca	0	0	0	4	10	0	14	71,42
Sombra	1	1	0	0	0	4	6	66,66
Total	208	144	55	145	12	27	591	
Acurácia do produtor %	83,65	93,05	83,63	72,41	83,33	14,81		

O modelo óptico obteve 80,03% de acurácia global e índice Kappa de 0,73. Tais resultados podem ser considerados muito bons, pois valores de Kappa entre 0,61 e 0,80 indicam uma forte concordância entre a classificação e os dados de referência. A acurácia do produtor da classe voçoroca foi de 83,33%, demonstrando bom desempenho em relação a verdade de terrestre. Já a acurácia do usuário para essa classe foi de 71,42%, uma vez que algumas regiões de solo exposto foram classificadas incorretamente como voçorocas.

A classe sombra obteve o menor valor para a acurácia do produtor (14,81), pois houve bastante confusão com a vegetação arbórea. Por outro lado, o pasto obteve a maior acurácia do produtor, apresentado pequena confusão com a classe campo sujo. Já a classe com maior acurácia do usuário foi o solo exposto e a classe com pior acurácia do usuário foi campo sujo (51,68), confundindo com o solo exposto e a vegetação arbórea.

A Tabela 10 apresenta a matriz de confusão para o modelo empírico combinado. Com exceção das voçorocas, as outras classes tiveram resultados similares tanto para o modelo óptico quanto para o modelo combinado. A classe voçoroca apresentou um resultado superior em relação à acurácia do usuário no modelo combinado. Tal resultado está relacionado com a diminuição dos objetos

falsos positivos, ou seja, regiões classificadas como voçorocas que apresentassem amostras de referência de outra classe.

Tabela 10. Matriz de confusão criada a partir do modelo combinado na área 1.

Classes	Veg arbórea	Pasto	Campo sujo	Solo exposto	Voçoroca	Sombra	Total	Acurácia do usuário %
Veg arbórea	174	1	4	1	0	23	203	85,71
Pasto	16	134	2	18	1	0	171	78,36
Campo sujo	17	8	46	17	1	0	89	51,68
Solo exposto	0	0	3	109	0	0	112	97,32
Voçoroca	0	0	0	0	10	0	10	100
Sombra	1	1	0	0	0	4	6	66,66
Total	208	144	55	145	12	27	591	
Acurácia do produtor %	83,65	93,05	83,63	75,17	83,33	14,81		

O modelo combinado obteve acurácia global de 80,71% e Kappa de 0,74. Resultado similar foi obtido por Liu et al. (2016), que relataram 84,62% de acurácia global. No entanto, os autores citados utilizaram dados de alta resolução espacial (0,2 m) para realizar o mapeamento, enquanto o presente estudo utilizou dados de média resolução espacial. Knight et al. (2007), por exemplo, ao utilizar imagens e MDE de média resolução ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer), obtiveram 50% de acurácia global para detectar voçorocas na Austrália. Os autores atribuíram a baixa acurácia à resolução espacial dos dados de entrada, de modo que as voçorocas maiores foram superestimadas e as menores subestimadas.

A Tabela 11 apresenta os resultados da avaliação da acurácia do mapa obtido a partir do método da árvore de decisão. De modo geral, essa classificação apresentou pior desempenho em todas as classes de uso do solo, resultando em uma acurácia global de 53,97% e índice Kappa 0,43. A classe com pior acurácia do usuário foi a voçoroca (10,14%). Esse resultado se deu em função do elevado número de falsos positivos, provenientes de regiões de pastagem e, principalmente, de solo exposto.

Tabela 11. Matriz de confusão criada a partir do algoritmo de árvore de decisão na área 1.

Classes	Veg arbórea	Pasto	Campo sujo	Solo exposto	Voçoroca	Sombra	Total	Acurácia do usuário %
Veg arbórea	103	2	2	0	0	15	122	84,42
Pasto	4	83	2	1	0	0	90	92,22
Campo sujo	38	8	46	14	2	0	108	42,59
Solo exposto	5	48	4	68	3	0	128	53,12
Voçoroca	0	3	0	59	7	0	69	10,14
Sombra	58	0	1	3	0	12	74	16,21
Total	208	144	55	145	12	27	591	
Acurácia do produtor %	49,51	57,63	83,63	46,89	58,33	44,44		

A classificação por árvore de decisão também apresentou uma acurácia do usuário baixa para a classe sombra, uma vez que 12 regiões foram classificadas como vegetação arbórea. Do mesmo modo, a acurácia do usuário do campo sujo também foi afetada negativamente pela confusão com a vegetação arbórea.

Já o mapeamento do pasto apresentou dois resultados discrepantes: sob a perspectiva dos segmentos classificados apresentou poucos erros, porém, sob a perspectiva da realidade no campo não conseguiu realizar a identificação correta em 61 pontos. Tal resultado está relacionado com escolha da unidade de análise da avaliação do mapeamento, a qual foi baseada em pontos amostrais. De acordo com Congalton e Green (2008), se o alvo a ser avaliado é um polígono, então as unidades de avaliação da acurácia devem ser polígonos.

A Tabela 12 apresenta a avaliação da acurácia obtida a partir da sobreposição das classificações das voçorocas com os polígonos de referência vetorizados. O desempenho geral das classificações, representado pelo índice F-measure, apresenta diferenças significativas entre os mapeamentos. O mapa gerado por árvore de decisão obteve um F-measure de apenas 5,83%, enquanto o modelo óptico obteve 34,8% e o modelo combinado 53,46%.

Tabela 12. Avaliação da acurácia a partir da sobreposição com os dados vetorizados na área 1.

Resultados	Modelo óptico	Modelo combinado	Modelo árvore de decisão
Área total das voçorocas (referência) (m ²)	4428	4428	4428
Área total classificada por GEOBIA (m ²)	11450	2750	45925
Área corretamente classificada (m ²)	2763	1919	1468
Falsos negativos (m ²)	1665	2509	2960
Falsos positivos (m ²)	8687	831	44457
Acurácia do produtor (AP) (%)	62,39	43,33	33,15
Acurácia do usuário (AU) (%)	24,13	69,78	3,19
F-measure (%)	34,80	53,46	5,83

Ao analisar a totalidade dos segmentos classificados, é possível verificar que a acurácia do usuário do modelo óptico e do modelo de árvore de decisão tiveram desempenhos inferiores àqueles obtidos pela matriz de confusão. A partir da sobreposição da classificação com dados de referência pôde-se obter uma informação mais precisa sobre extensão da área mapeada incorretamente. Dessa forma, o modelo óptico apresentou uma área total de falsos positivos superior ao dobro da área total de referência, enquanto o modelo da árvore de decisão apresentou um erro superior a dez vezes.

O modelo combinado também apresentou diminuição da acurácia a partir do método de sobreposição com dados vetorizados. A acurácia do usuário, que obteve valor de 100% na avaliação a partir de pontos amostrais, foi reduzida pra 69,78%. De forma similar, a acurácia do produtor também diminuiu ao considerar todo o polígono de referência. Apesar disso, essa forma de avaliação permitiu conhecer a verdadeira discrepância entre os modelos empíricos óptico e combinado. Assim, o modelo combinado teve um desempenho 34,90% superior ao modelo óptico.

É importante destacar que um dos motivos para o baixo desempenho do algoritmo de árvore de decisão é a impossibilidade de criar vários níveis de

segmentação da cena. Rodrigues (2014) afirma que a utilização de apenas um nível de segmentação elimina a possibilidade de relações contextuais interníveis, resultando em uma subutilização do conceito de segmentação multiresolução. Além disso, a impossibilidade de se criar um modelo combinando dados ópticos e altimétricos no *software* GEODMA também contribuiu com o baixo desempenho da árvore de decisão.

A comparação direta dos resultados obtidos nos estudos referentes ao mapeamento de voçorocas por GEOBIA se torna difícil, uma vez que existem diferenças quanto à resolução dos dados de entrada, quanto ao método de avaliação da acurácia e quanto ao tipo de alvo detectado. Liu et al. (2017), por exemplo, obtiveram 93,06% de acurácia a partir do F-measure na detecção de áreas afetadas por voçorocas utilizando imagens de alta resolução espacial. Porém, os estudos que detectam áreas afetadas por voçorocas não necessitam do delineamento preciso das voçorocas individuais, uma vez que objetivam fornecer apenas uma primeira impressão dos locais potencialmente afetados pela erosão (D'Oleire-Oltmanns et al. 2014).

Passo (2017) utilizou imagens RapidEye e MDE para detectar focos erosivos lineares no Distrito Federal, obtendo valores de kappa entre 48,6% a 72,9%. Assim, mesmo englobando sulcos, ravinas e voçorocas em uma única classe o autor encontrou dificuldades no mapeamento dessas feições em algumas áreas em função da confusão com as áreas de solo exposto.

5.2 Área de estudo 2

5.2.1 Classificação das voçorocas a partir do modelo óptico

A Figura 17 ilustra a classificação obtida a partir do modelo óptico empírico de GEOBIA na área 2. Das 3 voçorocas existentes nessa área, 2 foram classificadas corretamente e 5 segmentos foram falsos positivos. Nota-se que as regiões classificadas incorretamente como voçorocas pertencem às classes campo sujo e solo exposto.

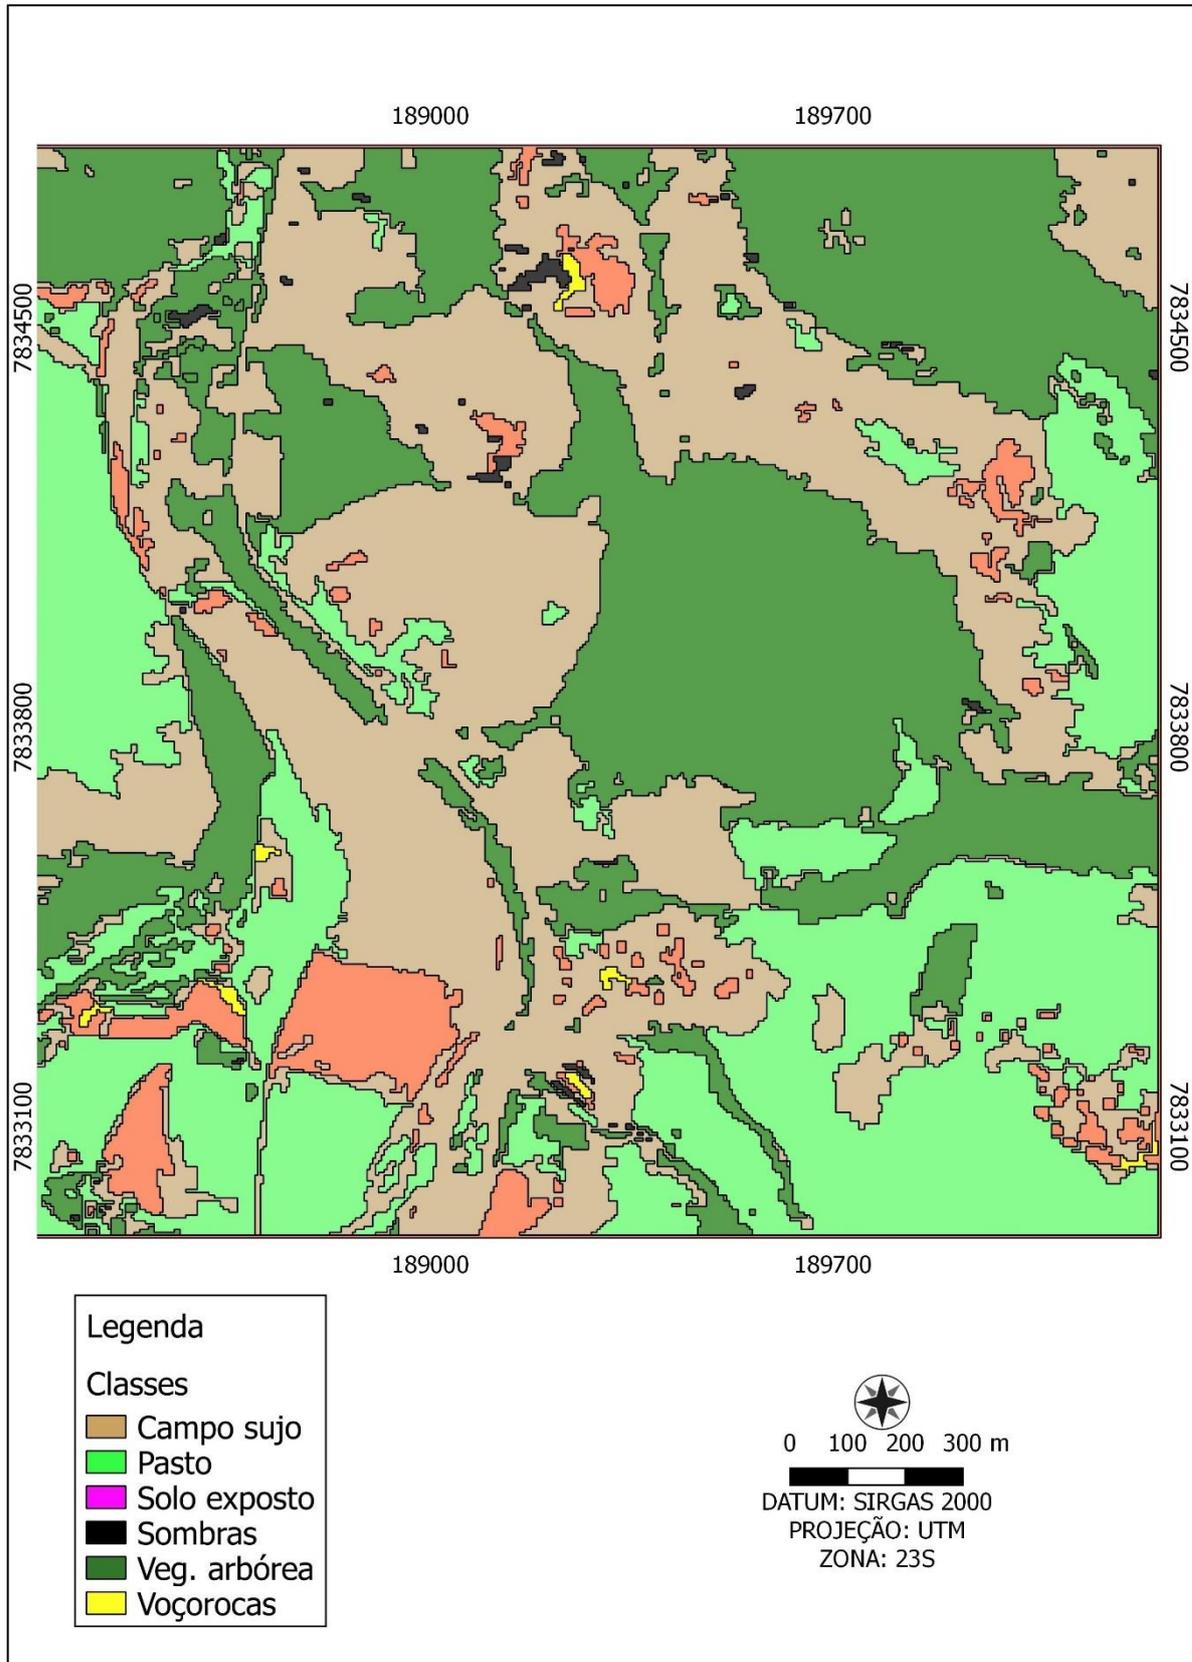


Figura 17. Classificação do uso e cobertura do solo a partir do modelo óptico na área 2.

A Figura 18 apresenta uma imagem real da voçoroca de maior extensão na área de estudo 2 obtida pelo Google Earth Pro. Nota-se que seu entorno é composto pela classe campo sujo e vegetação arbórea. Esse contraste entre as classes facilita a detecção da voçoroca, uma vez que apresenta maior quantidade de solo exposto em seu interior.



Figura 18. Imagem da voçoroca de maior extensão na área de estudo 2.

A Figura 19 apresenta o mapeamento das voçorocas em detalhes, sendo possível analisar as regiões que foram corretamente classificadas após a sobreposição com os polígonos de referência. A voçoroca não detectada (em azul) na Figura 19C apresenta uma mistura de solo exposto e vegetação rasteira, sendo confundida com o pasto. Já a Figura 19D evidencia um segmento falso positivo gerado a partir da confusão com uma bacia de contenção da água pluvial. Essas estruturas possuem características geométricas e espectrais similares às voçorocas, tornando difícil a diferenciação entre os alvos.

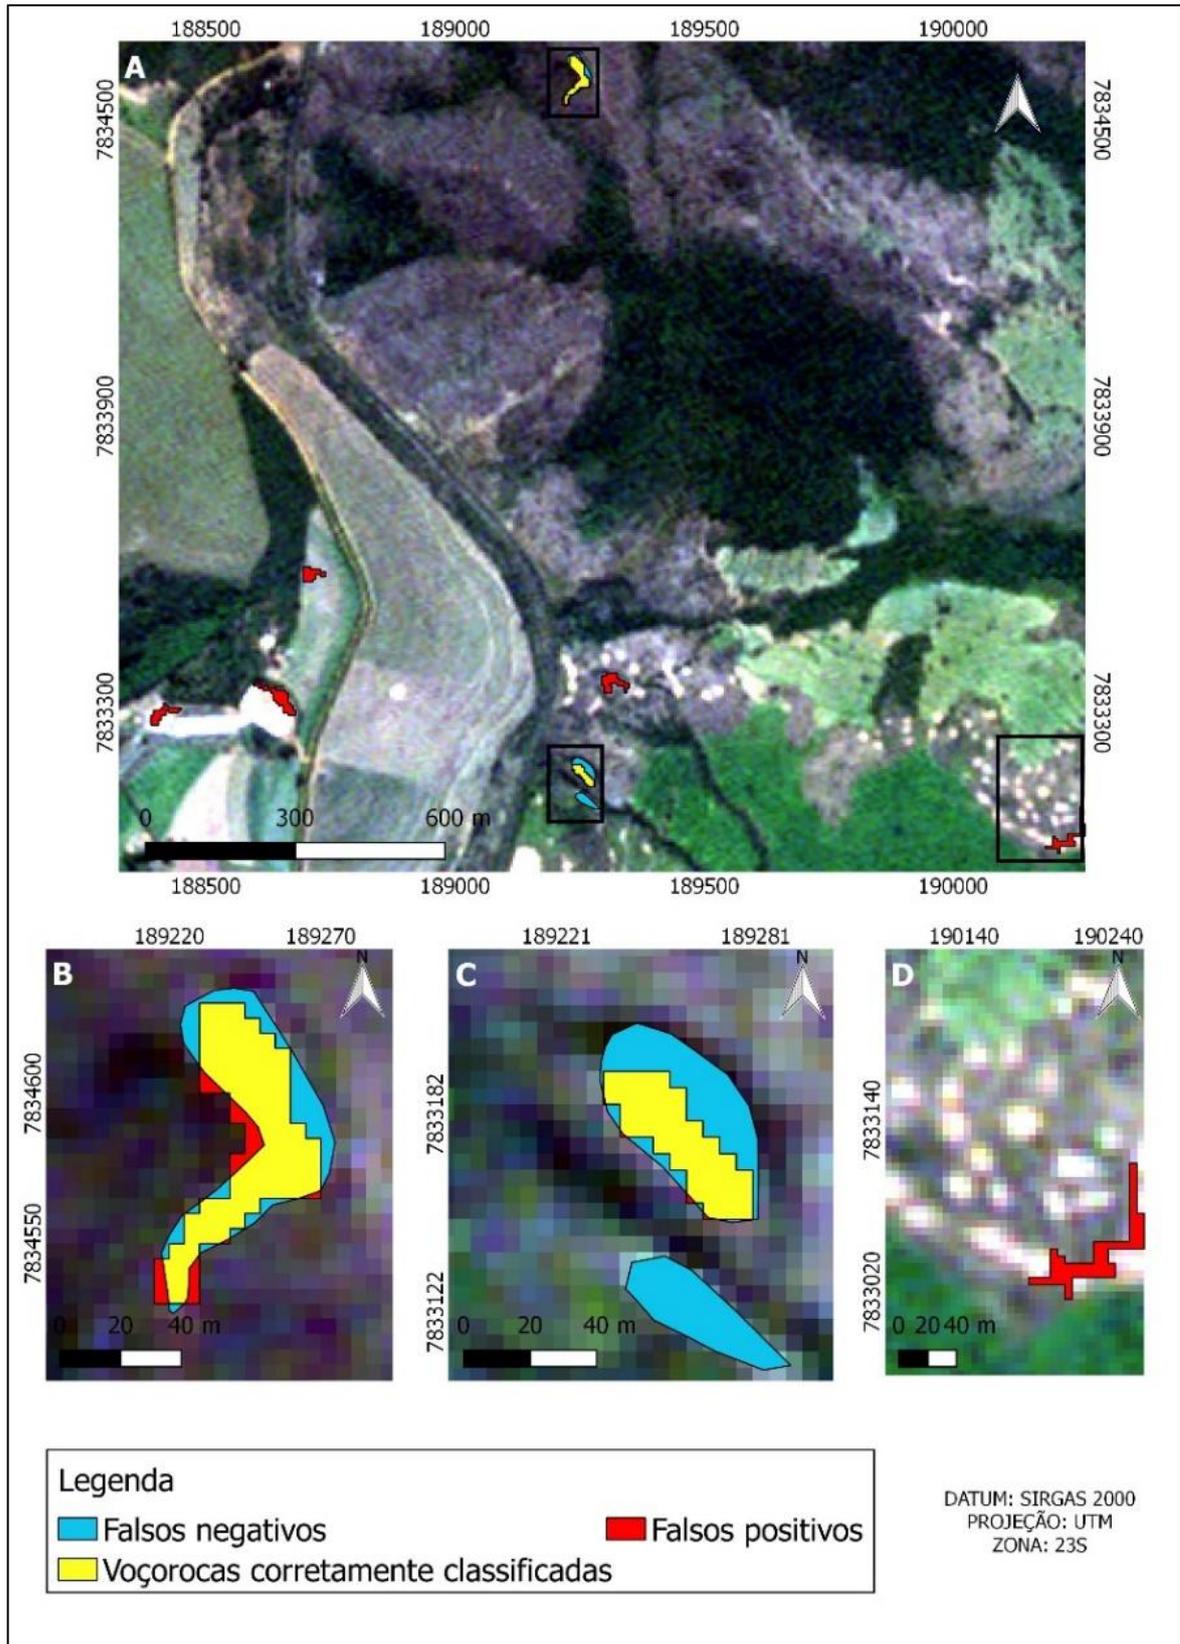


Figura 19. Detalhamento da classificação das voçorocas a partir do modelo óptico na área 2.

Já a sombra foi o principal motivo da omissão parcial do mapeamento da voçoroca na Figura 19C. Tal fato está relacionado com a ausência de parâmetros de detecção de sombras no modelo de classificação das voçorocas. Visando superar esse problema, D'Oleire-Oltmanns et al. (2014) utilizaram, dentre outras variáveis, a informação de contraste causada pela variação entre as áreas sombreadas e as áreas brilhantes das voçorocas. No entanto, mesmo utilizando a informação de contraste causado pelas sombras em imagens de alta resolução espectral, os autores citados obtiveram uma modesta acurácia no mapeamento das áreas afetadas por voçorocas.

5.2.2 Classificação das voçorocas a partir do modelo combinado

A Figura 20 ilustra a classificação do uso do solo a partir do modelo combinado. Assim como no modelo óptico, foram detectadas 2 das 3 voçorocas existentes na cena. No entanto, a introdução da declividade permitiu diminuir o número de falsos positivos de 5 para 3. Essa redução torna o modelo mais robusto, permitindo calcular, de forma mais precisa, área total ocupada pelos processos erosivos avançados.

Apesar de alguns estudos apresentarem acurácia aceitável no mapeamento de voçorocas utilizando somente dados ópticos, Liu et al. (2017) afirmam que a informação do relevo não deveria ser descartada por dois motivos: primeiramente, a imagem é facilmente afetada pela superfície do solo, especialmente a vegetação; segundo, a qualidade da imagem varia de acordo com as estações, condições do clima e altitudes, causando incertezas na distinção das feições.

Shruthi et al. (2012) utilizaram a GEOBIA para investigar a extração de feições de voçorocas de modo semi-automático em uma região do semiárido do Marrocos. Para isso, utilizaram imagens do satélite Ikonos 2 e GeoEye-1 com o objetivo de extrair informações topográficas, espectrais, geométricas e contextuais. Foi constatado que o método utilizado é mais rápido e eficiente do que os métodos tradicionais, porém os limiares utilizados são empíricos e necessita de mudanças de acordo a região.

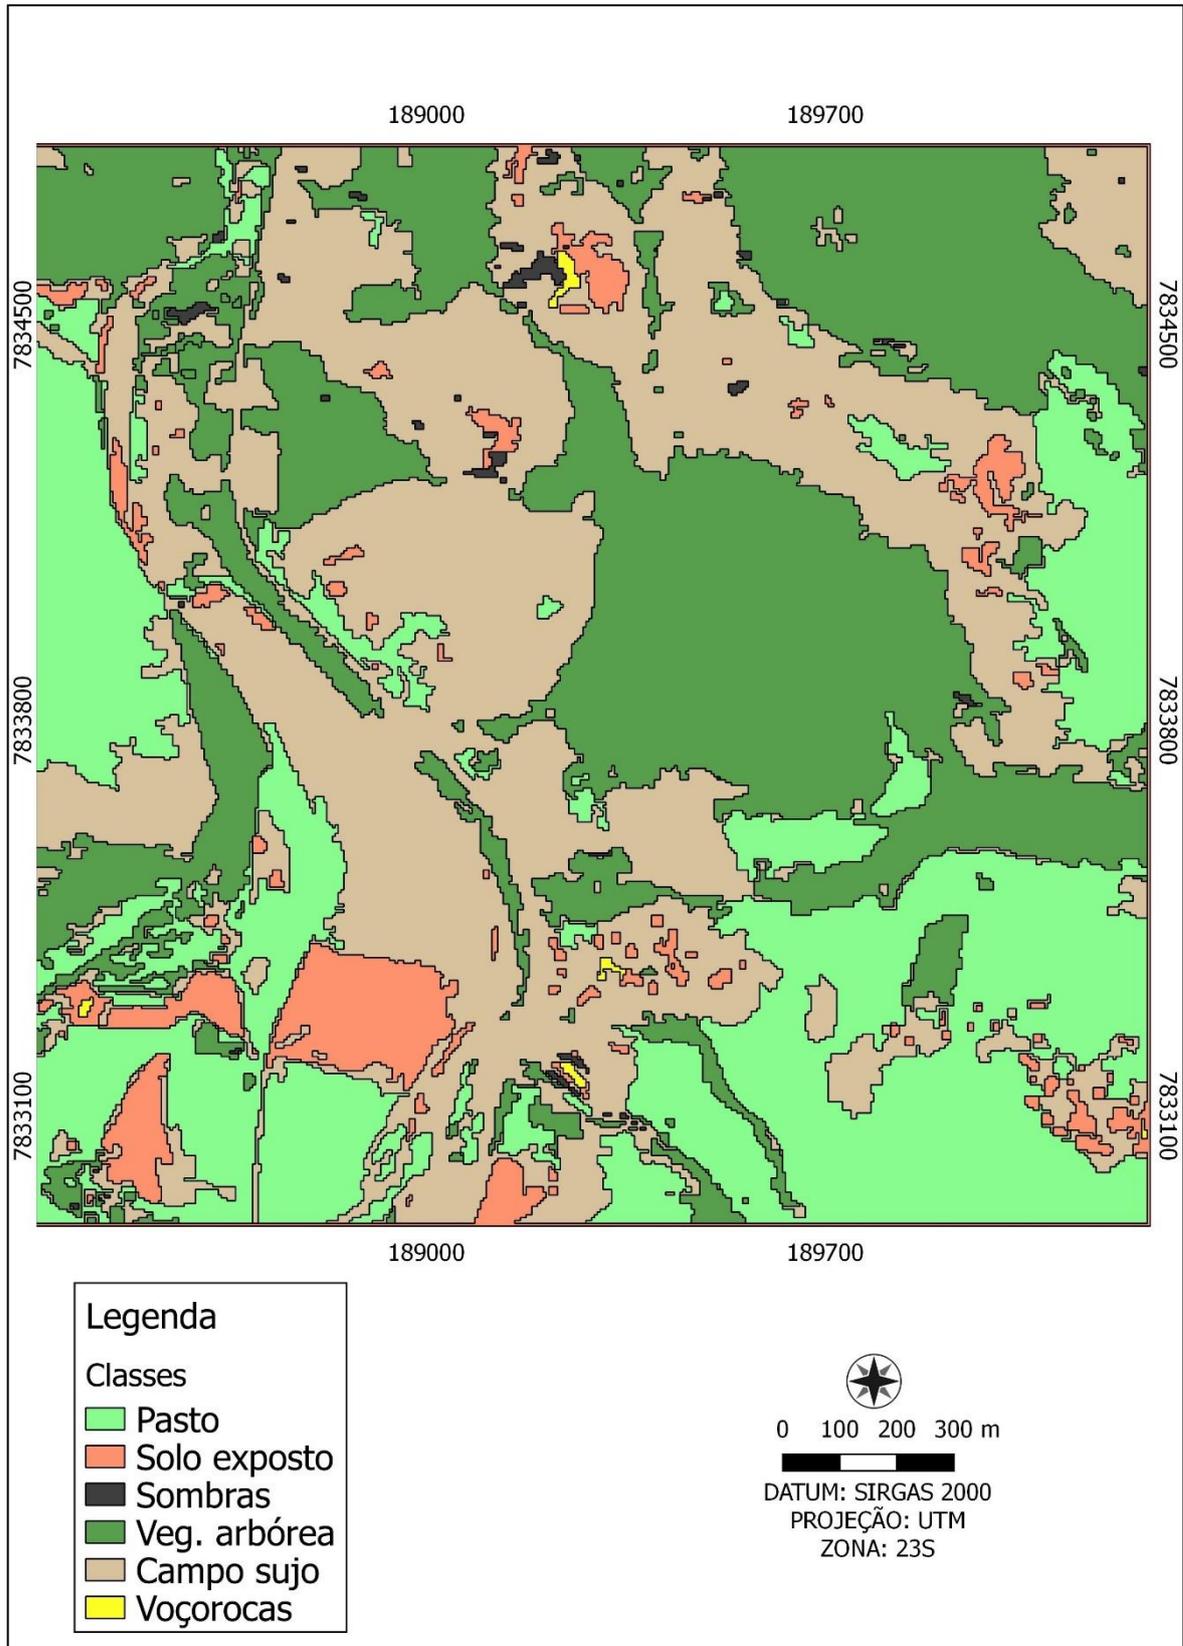


Figura 20. Classificação do uso e cobertura do solo a partir do modelo combinado na área 2.

A Figura 21 ilustra a classificação das voçorocas a partir do modelo combinado em detalhes. Assim como na área 1, a área 2 também apresenta apenas uma pequena porção da imagem ocupada pela classe voçoroca, conforme pode-se observar a partir da Figura 21A. A voçoroca mais extensa, ilustrada na Figura 21B, apresentou uma pequena diferença no mapeamento em relação ao modelo óptico, aumentando a área classificada corretamente em sua parte superior. Já a Figura 21D detalha uma região em que houve a diminuição de um segmento classificado incorretamente.

Destaca-se que o modelo utilizado para detectar voçorocas na área de estudo 2 é o mesmo empregado na área de estudo 1. A única adaptação necessária foi a criação de um nó com um valor de escala maior, em função de uma voçoroca mais extensa na área 2. Blaschke et al. (2014) comentam que, ao utilizar a GEOBIA, é preciso realizar ajustes do parâmetro escala em relação ao tamanho dos objetos detectáveis. Dependendo das características da área de estudo, a adoção de uma escala única não é suficiente para avaliar as variações em tamanho de todas as voçorocas. Por esse motivo, a escala se faz fundamental em uma estrutura hierárquica, na qual diversos níveis de captação da informação podem ser utilizados para evitar a segmentação excessiva de alguns alvos (Goodchild, 2001; Blaschke et al., 2004).

Alguns autores utilizaram a estratégia de estabelecer diferentes escalas no mapeamento de voçorocas por GEOBIA. Liu et al. (2017), por exemplo, obtiveram sucesso no mapeamento de áreas afetadas por voçorocas e voçorocas de ribanceira ao desenvolver uma estrutura hierárquica com dois níveis distintos de escalas. D'Oleire-Oltmanns et al. (2013) usaram dois níveis distintos de escalas para facilitar a detecção de voçorocas e outras formas de relevo criadas pela deposição glacial.

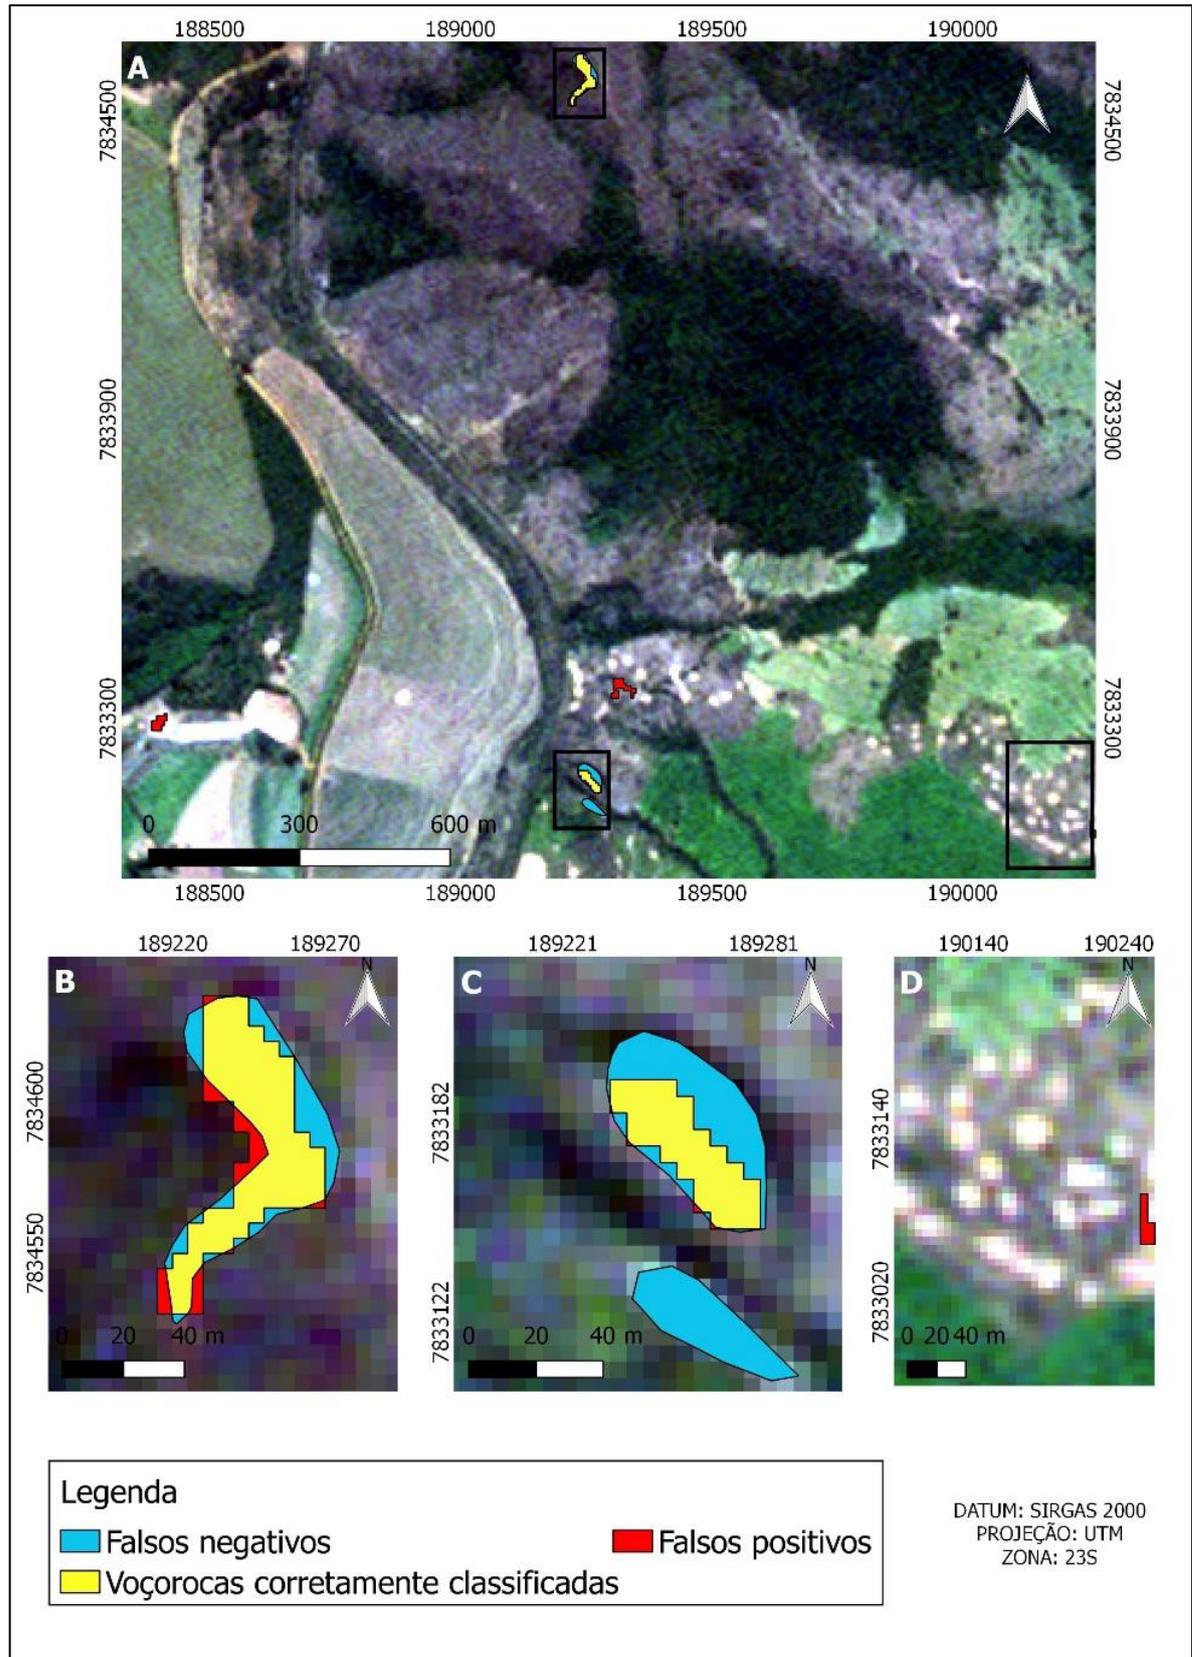


Figura 21. Detalhamento da classificação das voçorocas a partir do modelo combinado na área 2.

5.2.3 Classificação por árvore de decisão

A Figura 22 ilustra o resultado do mapeamento gerado pelo modelo de árvore de decisão. Nota-se que, apesar do modelo conseguir detectar o mesmo número de voçorocas que os modelos empíricos, houve um grande número de segmentos classificados incorretamente como voçorocas. Além das limitações apresentadas na área de estudo 1 para o método da árvore de decisão, a área de estudo 2 possui menos voçorocas para realizar o treinamento do algoritmo, dificultando a extração de atributos que descrevam essa classe automaticamente.

O modelo automático de classificação das voçorocas, baseado no algoritmo de árvore de decisão apresentou desempenho inferior ao modelo empírico nas duas áreas de estudo. Por outro lado, alguns autores relataram bons resultados no mapeamento de voçorocas utilizando outros algoritmos de mineração de dados.

Tedesco (2015) utilizou um *software* de árvore de decisão denominado *Classification and Regression Tree* (CART) para obter os parâmetros mais relevantes que seriam empregados no modelo de GEOBIA para delimitar voçorocas na região de Uberlândia-MG. Foram utilizados dados espectrais, provenientes de imagens Ikonos, associados a dados altimétricos, oriundos de dados LIDAR. Por fim, a autora comparou as classificações finais do método da GEOBIA e por árvores de decisão, obtendo melhor desempenho com o primeiro método, uma vez que ele permite o uso de escalas diferentes, a inserção da incerteza e a inserção do conhecimento.

Ao utilizar o algoritmo de mineração de dados *Random Forests*, Shruthi et al. (2014) constataram que os parâmetros mais relevantes para detectar áreas afetadas por voçorocas foram brilho, *Maxdiff* e $NDVI_{RE}$. Os autores obtiveram 81% de acurácia global mesmo utilizado imagens Aster como dados de entrada do modelo, demonstrando a viabilidade do *Random Forests*, mesmo utilizando dados de média resolução espacial.

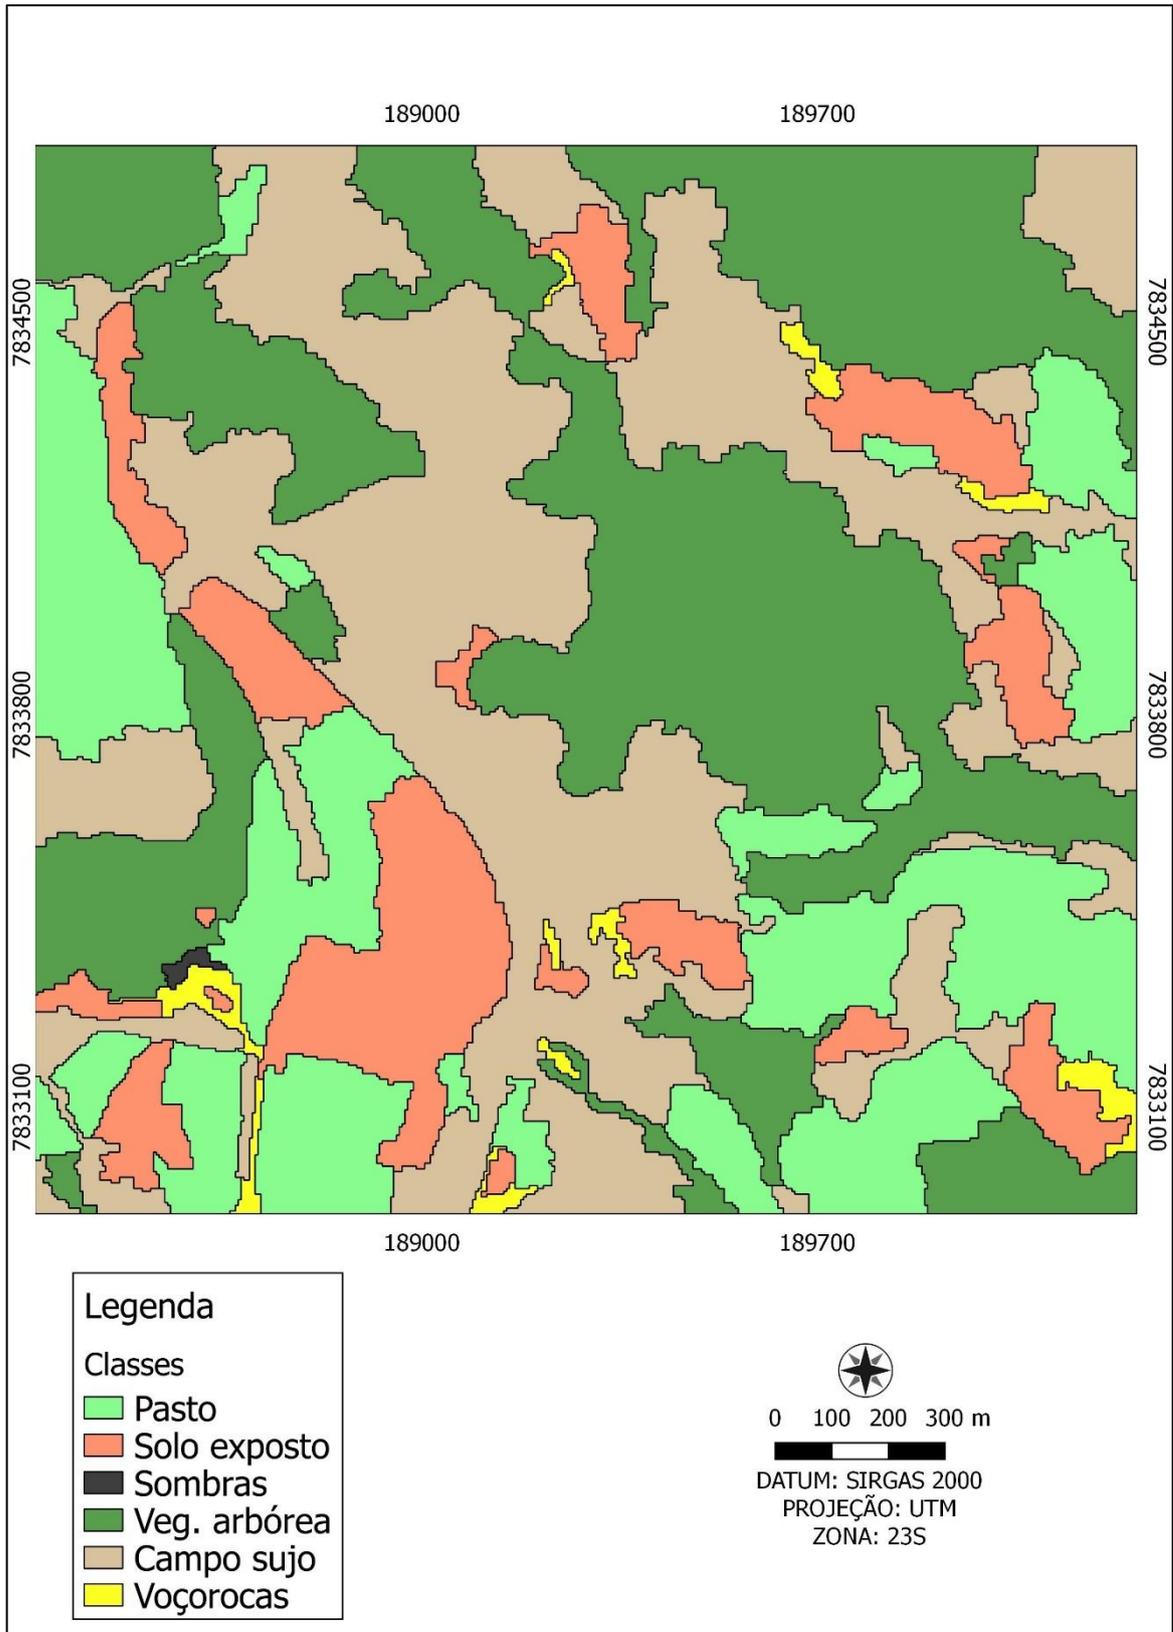


Figura 22. Classificação do uso e cobertura do solo a partir da árvore de decisão na área 2.

A Figura 23 ilustra o resultado detalhado das regiões classificadas corretamente, os falsos positivos e falsos negativos para a classe voçoroca. Nota-se que a voçoroca ilustrada na Figura 23B apresentou algumas mudanças no delineamento das bordas, alterando a quantidade de falsos positivos e negativos em relação aos mapas anteriores. Tal fato também pode ser notado na voçoroca detectada na Figura 23C, a qual possui uma nova região mapeada como falso positivo. Já a Figura 23D exemplifica a confusão do modelo em áreas de campo sujo e solo exposto.

D'Oleire-Oltmanns et al. (2014) mencionam a heterogeneidade de classes como um dos motivos da modesta acurácia (62% de acurácia global) obtida na classificação orientada a objetos de áreas afetadas por voçorocas em Marrocos. Apesar de utilizar imagens QuickBird-2, os autores criaram um modelo que apresentava confusões com outras classes, principalmente solo exposto.

Uma das razões para a classificação incorreta das voçorocas é a existência de estruturas para captação da chuva nessa área. Essas estruturas podem ser visualizadas mais facilmente na Figura 23D, sendo similares em brilho e forma às voçorocas. Outros locais que causaram confusão do modelo foi locais com edificações, as quais possuíam alto brilho em todas as bandas espectrais.

Vrieling (2006) aponta a detecção de voçorocas individuais como um dos principais gargalos dentre as pesquisas que utilizam o sensoriamento remoto para avaliação dos efeitos da erosão hídrica. Tal fato se justifica, pois, as voçorocas individuais, em geral, apresentam maiores confusões espectrais e de forma, principalmente em ambientes antropizados.

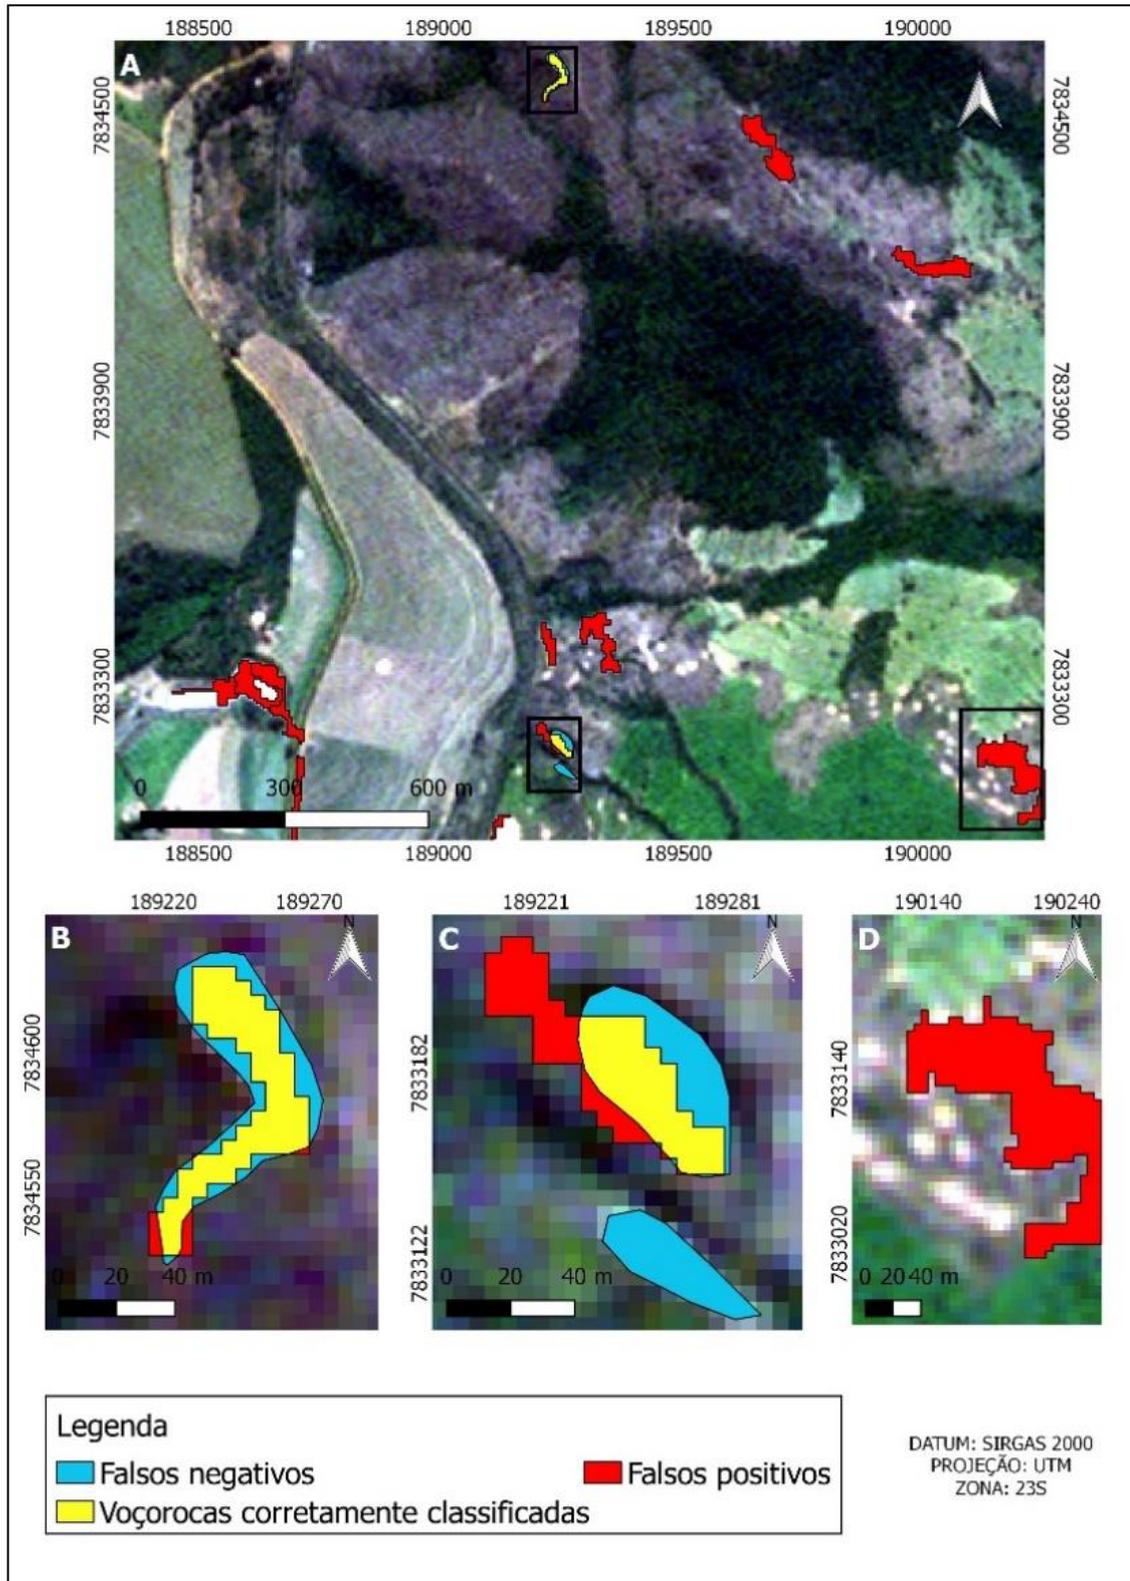


Figura 23. Detalhamento da classificação das voçorocas a partir do algoritmo de árvore de decisão na área 2.

5.2.4 Avaliação da acurácia

A acurácia global da classificação pelo modelo óptico foi de 71,08% e índice Kappa 0,62, os quais podem ser considerados muito bons segundo Landis e Koch (1977). Os estudos que utilizam apenas dados ópticos para a detecção de voçorocas são importantes pois oferecem uma alternativa para situações em que não é possível obter dados altimétricos para a região. No entanto, a acurácia obtida geralmente com esses dados de entrada ainda apresenta desempenho inferior em relação aos estudos que utilizam modelos digitais de elevação. Mararakanye e Nethengwe (2012), por exemplo, tiveram uma acurácia moderada da classificação (kappa 0,52) ao utilizar apenas imagens do SPOT 5. Já D'Oleire-Oltmanns (2014), mesmo utilizando imagens de alta resolução espacial Quickbird-2 tiveram 62% de acurácia global. A Tabela 13 apresenta a matriz de confusão do modelo óptico.

Tabela 13. Matriz de confusão criada a partir do modelo óptico na área 2.

Classes	Veg arbórea	Pasto	Campo sujo	Solo exposto	Voçoroca	Sombra	Total	Acurácia do usuário %
Veg arbórea	96	3	5	0	0	11	115	83,47
Pasto	34	99	18	15	0	1	167	59,28
Campo sujo	16	6	96	26	1	2	147	65,30
Solo exposto	2	0	5	77	1	0	85	90,58
Voçoroca	0	0	2	4	9	0	15	60
Sombra	3	0	0	0	0	4	7	57,14
Total	151	108	126	122	11	18	536	
Acurácia do produtor %	63,57	91,66	76,14	63,11	81,81	22,22		

Em relação à classe voçoroca, houve uma acurácia do usuário de 60%, indicando que algumas regiões foram classificadas incorretamente. Essas regiões que causaram o erro eram constituídas por campo sujo e, principalmente, solo exposto. A acurácia do produtor da classe voçoroca apresentou melhor desempenho (81,81%), indicando a robustez do modelo em detectar voçorocas existentes no campo, mesmo quando ocupam uma pequena porção da imagem.

Os resultados de acurácia do modelo combinado a partir da matriz de confusão são apresentados na Tabela 14. Esse modelo apresentou um desempenho

geral similar ao modelo óptico, com acurácia global de 71,26% e Kappa 0,62. No entanto, é possível notar a melhora da classificação das voçorocas no modelo combinado, pois apresentou 75% de acurácia do usuário, ou seja, gerou menos falsos positivos.

Tabela 14. Matriz de confusão criada a partir do modelo combinado na área 2.

Classes	Veg arbórea	Pasto	Campo sujo	Solo exposto	Voçoroca	Sombra	Total	Acurácia do usuário %
Veg arbórea	96	3	5	0	0	11	115	83,47
Pasto	34	99	19	15	0	1	168	58,92
Campo sujo	16	6	96	27	1	2	148	64,86
Solo exposto	2	0	5	78	1	0	86	90,69
Voçoroca	0	0	1	2	9	0	12	75
Sombra	3	0	0	0	0	4	7	57,14
Total	151	108	126	122	11	18	536	
Acurácia do produtor %	63,57	91,66	76,19	63,93	81,81	22,22		

O modelo gerado pelo método da árvore de decisão apresentou piores resultados, tanto para a classe voçoroca, quanto para as demais classes. A acurácia global foi de 55,43% e o índice Kappa 0,44. Em relação às voçorocas, destaca-se a acurácia do produtor de 100%, demonstrando que, sob o ponto de vista da verdade terrestre não houve erro. Porém, a avaliação da acurácia a partir de amostras de validação pontuais não reflete a real extensão das voçorocas no campo, uma vez que existem regiões de voçorocas não detectadas. Além disso, houve muitos segmentos classificados incorretamente, resultando em uma acurácia do usuário de 13,51%. A Tabela 15 apresenta os resultados da avaliação da acurácia do modelo de árvore de decisão.

Tabela 15. Matriz de confusão criada a partir da árvore de decisão na área 2.

Classes	Veg arbórea	Pasto	Campo sujo	Solo exposto	Voçoroca	Sombra	Total	Acurácia do usuário %
Veg arbórea	73	4	3	0	0	14	94	77,6
Pasto	6	84	15	9	0	0	114	73,68
Campo sujo	24	21	69	3	0	1	118	58,47
Solo exposto	2	4	28	59	0	0	93	63,44
Voçoroca	4	0	14	46	10	0	74	13,51
Sombra	37	0	0	3	0	1	41	2,43
Total	146	113	129	120	10	16	534	
Acurácia do produtor %	50	74,33	53,48	49,16	100	6,25		

A Tabela 16 sintetiza os resultados da acurácia global e do índice Kappa nas duas áreas de estudos. Nota-se que, de maneira geral, a acurácia dos modelos empíricos foi superior aos modelos criados pela árvore de decisão nas duas áreas de estudos. Esse resultado pode ser atribuído ao pequeno número de amostras de treinamento para a classe voçoroca e pela segmentação única no *software* de árvore de decisão.

Conforme citado anteriormente, não é possível variar a escala e os pesos da cor e compacidade para cada classe no Geodma, diminuindo sua eficiência. Assim, os objetos criados podem não corresponder aos alvos em campo, alterando-se os parâmetros criados para cada classe. Para a classe voçoroca, por exemplo, tanto na área 1 quanto na área 2, os parâmetros texturais de homogeneidade e entropia estabelecem uma baixa textura, sendo que o esperado seria o oposto.

Tabela 16. Resultados da acurácia global e do índice Kappa nas duas áreas.

Área de estudo	Avaliação da acurácia	Modelo óptico	Modelo combinado	Modelo árvore de decisão
Área 1	Acurácia Global	80,03	80,71	53,97
	Índice Kappa	0,73	0,74	0,43
Área 2	Acurácia Global	71,08	71,26	55,43
	Índice Kappa	0,62	0,62	0,44

A partir da comparação da classificação com os dados de referência criados manualmente (Tabela 17) é possível notar que o modelo combinado apresentou desempenho 28,65% superior ao modelo óptico. Embora a acurácia do produtor tenha obtido valores aproximados nos três modelos, os valores dos F-measure foram bem distintos. Esse resultado se deu em função do número de falsos positivos obtidos em cada modelo, de modo que o modelo óptico e, principalmente o modelo da árvore de decisão, apresentaram baixa acurácia do usuário.

Tabela 17. Avaliação da acurácia a partir da sobreposição com os dados vetorizados na área 2.

Resultados	Modelo óptico	Modelo combinado	Árvore de decisão
Área total das voçorocas (referência) (m ²)	5110	5110	5110
Área total classificada por GEOBIA (m ²)	9078	5013	50567
Área corretamente classificada (m ²)	2832	2832	2810
Falsos negativos (m ²)	2278	2278	2300
Falsos positivos (m ²)	6246	2181	47757
Acurácia do produtor (AP) (%)	55,42	55,42	54,99
Acurácia do usuário (AU) (%)	31,19	56,49	5,55
F-measure (%)	39,92	55,95	10,09

Nota-se que a área corretamente classificada foi aproximadamente a mesma nos três modelos gerados. Esse resultado pode estar relacionado com o maior contraste das voçorocas com o seu entorno na área de estudo 2, facilitando sua detecção. Por outro lado, a área de estudo 1 possui áreas erodidas ao redor de algumas voçorocas, dificultando do delineamento preciso dessas feições. Essas diferentes características nas duas áreas de estudos confirmam a robustez do modelo empírico combinado, o qual conseguiu detectar as voçorocas e gerar poucos falsos positivos.

6 CONCLUSÕES

O mapeamento semiautomático de voçorocas individuais a partir de imagens RapidEye e dados SRTM é eficiente ao utilizar o método da Análise de Imagens Baseada em Objetos Geográficos. A otimização do processo de segmentação a partir do índice SEI proporciona a criação de objetos com geometria mais semelhante às voçorocas, permitindo a extração de características específicas dessas feições erosivas.

A introdução do parâmetro declividade ao modelo aprimora a acurácia do mapeamento das voçorocas em 34,90 % na área 1 e 28,65% na área 2. As voçorocas pequenas, com menos de 10 m de largura não foram detectadas em função da resolução dos dados de entrada. Os modelos criados manualmente apresentam desempenho superior ao modelo supervisionado de árvore de decisão. Embora o modelo empírico apresente um certo grau de subjetividade, a utilização do *software* de mineração de dados permitiu a escolha dos parâmetros de forma mais rápida.

É possível utilizar o mesmo conjunto de regras de classificação das voçorocas nas duas áreas de estudos, indicando a transferibilidade do modelo empírico. A avaliação da acurácia do mapeamento das voçorocas a partir da sobreposição com dados de referência vetorizados é superior ao tradicional método de avaliação a partir de pontos amostrais. O *software* InterIMAGE mostrou-se eficiente para o mapeamento das voçorocas por GEOBIA. Todos os programas e dados de entrada utilizados nesse estudo são gratuitos, tornando mais fácil sua difusão para outras regiões.

7 REFERÊNCIAS

- Almeida Filho GS (2000) **Diagnóstico de processos erosivos lineares associados a eventos Pluviosos no Município de Bauru, SP**. 186 f. Dissertação (Mestrado em Engenharia Civil). Universidade Estadual de Campinas, Campinas.
- Antunes AFB (2003) **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. 147 f. Tese (Doutorado) - Universidade Federal do Paraná, Curitiba.
- Araújo GHS, Almeida JR, Guerra AJT (2008) **Gestão Ambiental de Áreas Degradadas**. Rio de Janeiro: Bertrand Brasil, 322 p.
- Baatz M, Schape A (2000) Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. In: Applied Geographical Information Processing XII. **Anais...Heidelberg**: Herbert Wichmann Verlag, p. 12-23.
- Bacellar LAP (2000) **Condicionantes geológicas, geomorfológicas e geotécnicas dos mecanismos de voçorocamento na bacia do rio Maracujá Ouro Preto, MG**. Tese (Doutorado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- Bacellar LAP (2006) **Processos de formação de voçorocas e medidas preventivas e corretivas**. Universidade Federal de Ouro Preto. Ouro Preto.
- Baghdadi N, Mallet C, Zribi M (2018) **QGIS and Generic Tools**. Wiley, 310 p.
- Wiley. Bekkar M, Djemaa HK, Alitouche TA (2013) Evaluation Measures for Models Assessment over Imbalanced Data Sets. **Journal of Information Engineering and Applications** 3: 27-38.
- Bento BMP (2016) **Avaliação de classificadores por árvore de decisão e árvore de regressão em cenas urbanas do sensor WorldView-2**. 140 f. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos.
- Benz UC, Hofmann P, Willhauck G, Lingenfelder I, Heynen M (2004) Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry and Remote Sensing** 58: 239-258.
- Bertoni J, Lombardi Neto F (1990) **Conservação do solo**. São Paulo: Ícone, 355p.
- Bigarella JJ, Mazuchowski JZ (1985) Visão integrada da problemática da erosão. In: Simpósio nacional de controle de erosão. **Anais...** Maringá, ABGE, ADEA, 1985, p. 322.

Blaschke T, Strobl J (2001) What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. **GeoBIT/GIS** 6:12-17.

Blaschke T, Burnett C, Pekkarinen A (2004) New contextual approaches using image segmentation for objectbased classification. Dordrecht: Kluwer Academic Publishers, p. 211-236.

Blaschke T (2010) Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing** 65:2-16.

Blaschke T, Hay GJ, Kelly M, Lang S, Hofmann P, Addink E, Queiroz Feitosa R, van der Meer F, van der Werff H, van Coillie F, Tiede D (2014) Geographic Object-Based Image Analysis – Towards a new paradigm. **ISPRS Journal of Photogrammetry and Remote Sensing** 87:180-191.

Botelho RGM, Guerra AJT (2003) Erosão dos solos. Rio de Janeiro: Bertrand Brasil, p. 181-220.

Camapum de Carvalho J, Sales MM, Sousa NM, Melo MTS (2006) Processos erosivos no Centro-Oeste Brasileiro. Brasília: Finatec, 464 p.

Carvalho DF, Durigon VL, Antunes MAH, Almeida WS, Oliveira PTS (2014) Predição da erosão do solo com uso da Rusle e séries temporais de NDVI do Landsat 5 TM. **Pesquisa Agropecuária Brasileira** 49:215-224.

Casalí J, Giménez R, Bennett S (2009) Gully erosion processes: monitoring and modelling. **Earth Surface Processes and Landforms** 34:1839-1840.

Castillo C, Gómez JA (2016) A century of gully erosion research: Urgency, complexity and study approaches. **Earth-Science Reviews** 160:300-319.

Cerri LES, Silva JAF, Santos PHP (1997) Erosão do Solo: Aspectos Conceituais. **Revista Geociências**, 92-98.

Chen Z, Chen W, Li C, Pu Y, Sun H (2016) Effects of polyacrylamide on soil erosion and nutrient losses from substrate material in steep rocky slope stabilization projects. **Science of The Total Environment**, 26-33.

Chen Y, MING D, ZHAO L, LV B, ZHOU K, QING Y (2018) Review on High Spatial Resolution Remote Sensing Image Segmentation Evaluation. **Photogrammetric Engineering & Remote Sensing**, 629-646.

Clinton N, Holt A, Scarborough J, Yan L, Gong P (2010) Accuracy Assessment Measures for Object-based Image Segmentation Goodness. **Photogrammetric Engineering & Remote Sensing**, 76:289-299.

Congalton RG (1991) A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment** 37:35-46.

Congalton RG, Green K (1999) *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. New York: Lewis Publishers, 137 p.

Congalton RG, Green K (2008) *Assessing the Accuracy of Remotely Sensed Data : Principles and Practices, Second Edition*. New York: CRC Press, 200 p.

Costa GAOP, Pinho CMD, Feitosa RQ, Almeida CM, Kux HJH, Fonseca LMG, Oliveira DAB (2008) InterIMAGE: uma plataforma cognitiva open source para a interpretação automática de imagens digitais. **Revista Brasileira de Cartografia** 60:331-337.

Coutinho AC (1997) **Segmentação e classificação de imagens LANDSAT-TM para o mapeamento dos usos da terra na região de Campinas, SP**. 150 f. Dissertação (Mestrado em Ciências) - Universidade de São Paulo, São Paulo.

Couto BOC (2015) **Análise de erodibilidade em taludes com horizontes resistentes e suscetíveis aos processos erosivos**. 124 f. Dissertação (Mestrado em Geotecnia) - Universidade Federal de Ouro Preto, Ouro Preto.

Davis J, Goadrich M (2006) The relationship between Precision-Recall and ROC curves. In: *Proceedings of the 23rd International Conference on Machine Learning*, Pittsburgh, p. 233-240.

Derosé RC, Gomez B, Marden M, Trustrum NA (1998) Gully erosion in Mangatu Forest, New Zealand, estimated from digital elevation models. **Earth Surface Processes and Landforms** 23:1045-1053.

Dikau R (1990) Derivatives from detailed geoscientific maps using computer methods. **Zeitschrift für Geomorphologie** 80:40-55.

Eustace A, Pringle M, Witte C (2009) Give Me the Dirt: Detection of Gully Extent and Volume Using High-Resolution Lidar. In: *Innovations in Remote Sensing and Photogrammetry*. Berlin, Springer, p. 255-269.

Evelpidou N, Figueiredo T (2009) **Soil protection in sloping mediterranean agri-environments: lectures and exercises**. Portugal: Instituto Politécnico de Bragança, 320 p.

Fayyad U, Piatetsky-Shapiro G, Smyth P (1996) *From data mining to knowledge discovery*. Menlo Park: AAAI Press.

Fendrich R, Obladen ML, Aisse MM, Garcias CM (1997) *Drenagem e Controle da Erosão Urbana*. Curitiba: Editora Universitária Champagnat, 486 p.

Francisco CN, Almeida CMD (2012) Performance evaluation of statistical and textural attributes in an object-based land cover classification. **Geodetic Sciences Bulletin** 18:302–326.

Franco MRS (2015) **Formação de ravinas: significância para a perda de solo por erosão hídrica**. Dissertação (Mestrado em Gestão dos recursos florestais) - Instituto Politécnico de Bragança, Bragança.

Furlani GM (1980) **Estudo geomorfológico das boçorocas de Casa Branca**. 376 f. Dissertação (Mestrado em Geografia) - Universidade de São Paulo, São Paulo.

Gitelson A, Merzlyak MN (1994) Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology** 22:247-252.

Goldschmidt R, Passos E (2005) **Data Mining um Guia Prático**. Rio de Janeiro: Elsevier, 296 p.

Gonçalves JLM (2002) **Conservação e cultivo de solos para plantações florestais**. Piracicaba: Gonçalves JL, Stape JL (Eds.), 498 p.

Goodchild MF (2001) Metrics of scale in remote sensing and GIS. **International Journal of Applied Earth Observation and Geoinformation** 3:114-120.

Grande TO, Almeida T, Cicerelli RE (2016) Object-oriented classification in association with accumulated reflectance and data mining tools. **Pesquisa Agropecuária Brasileira** 51:1983-1991.

Guerra AJT, Cunha, SB (Org.) (1994) **Processos erosivos nas encostas**. Rio de Janeiro: Bertrand Brasil, 458 p.

Guerra AJT, Cunha, SB (Org.) (1998) **Processos erosivos nas encostas**. Rio de Janeiro: Bertrand Brasil, 472 p.

Guerra AJT (2010) **Erosão e conservação dos solos: conceitos, temas e aplicações**. Rio de Janeiro: Bertrand Brasil, 337 p.

Hall MA (1998) **Correlation-Based Feature Selection for Machine Learning**. 198 f. Thesis (Doctor of Philosophy) - University of Waikato, Hamilto, New Zealand.

Hay GJ, Niemann K, McLean GF (1996) An object-specific image-texture analysis of H-resolution forest imagery. **Remote Sensing of Environment** 55:108-122.

Ide DM (2009) **Investigação geotécnica e estudo de um processo erosivo causado por ocupação urbana**. Dissertação (Mestrado em Geotecnia) - USP, São Paulo.

Infanti Jr. N, Fornasari Filho N (1998) Processos de dinâmica superficial. São Paulo: Associação Brasileira de Geologia de Engenharia.

Ionita I, Fullen MA, Zgłobicki W, Poesen J (2015) Gully erosion as a natural and human-induced hazard. **Natural Hazards** 79:1-5.

Johansen K, Taihei S, Tindall D, Phinn S (2012) Object-based Monitoring of Gully Extent and Volume in North Australia using LiDAR Data. In: Proceedings of the 4th GEOBIA. Rio de Janeiro, p. 168-173.

Karami A, Khorani A, Noohegar A, Shamsi SRF, Moosavi V (2015) Gully Erosion Mapping Using Object-Based and Pixel-Based Image Classification Methods Gully Erosion Mapping. **Environmental and Engineering Geoscience** 21:101-110.

Kinnel, PIA (1988) The influence of flow discharge on sediment concentrations in raindrops induced flow transport. **Australian Journal of Soil Research** 26:565-582.

Knight JM, Spencer J, Brooks A (2007) Large-area, high-resolution remote sensing based mapping of alluvial gully erosion in Australia's tropical rivers. In: Fifth Australian Stream Management Conference, Albury, p. 199-204.

Kohavi R, John GH (1997) Wrappers for feature subset selection. **Artificial Intelligence** 97:273-324.

Korting TS (2012) **GeoDMA: a toolbox integrating data mining with object-based and multi-temporal analysis of satellite remotely sensed imagery**. 119 f. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos.

Korting TS, Dutra LV, Fonseca LMG (2011) A Resegmentation Approach for Detecting Rectangular Objects in High-Resolution Imagery. **IEEE Geoscience and Remote Sensing Letters** 8:621-625.

Labatut V, Cherifi H (2011) Accuracy Measures for the Comparison of Classifiers. In: The 5th International Conference on Information Technology. Amman, Al-Zaytoonah University of Jordan.

Lal R (1988) Soil erosion research methods. Ankeny: Soil and Water Conservation Society, p. 141-160.

Lal R (1994) Soil erosion research methods. Ankeny: Soil and Water Conservation Society, 340 p.

Landis JR and Koch GG 1977. The measurement of observer agreement for categorical data. **Biometrics** 33:159-174.

Lepsch IF (2011) 19 lições de pedologia. São Paulo: Oficina de Textos, 456 p.

Li P, Xiao X (2007) Multispectral image segmentation by a multichannel watershed-based approach. **International Journal of Remote Sensing** 28:4429-4452.

Lillesand TM, Kiefer RW (1994) Remote Sensing and Image Interpretation. Crawfordsville: Wiley and Sons.

Lima MC (2003) **Degradação físico-química e mineralógica de maciços junto às voçorocas**. 336 f. Tese (Doutorado em Geotecnia) - Universidade de Brasília, Brasília.

Liu Y, Bian L, Meng Y, Wang H, Zhang S, Yang Y, Shao X, Wang B (2012) Discrepancy measures for selecting optimal combination of parameter values in object-based image analysis. **ISPRS Journal of Photogrammetry and Remote Sensing** 68:144-156.

Liu K, Ding H, Tang G, Na J, Huang X, Xue Z, Yang X, Li F (2016) Detection of Catchment-Scale Gully-Affected Areas Using Unmanned Aerial Vehicle (UAV) on the Chinese Loess Plateau. **ISPRS International Journal of Geo-Information** 5:238.

Liu K, Ding H, Tang G, Zhu A-X, Yang X, Jiang S, Cao J (2017) An object-based approach for two-level gully feature mapping using high-resolution DEM and imagery: a case study on hilly loess plateau region, China. **Chinese Geographical Science** 27:415-430.

Lizarazo I (2014) Accuracy assessment of object-based image classification: another STEP. **International Journal of Remote Sensing** 35:6135-6156.

Luffman IE, Nandi A, Spiegel T (2015) Gully morphology, hillslope erosion, and precipitation characteristics in the Appalachian Valley and Ridge province, southeastern USA. **Catena** 133:221-232.

Machado RL (2006) **Perda de solo e nutrientes em voçorocas com diferentes níveis de controle e recuperação no médio vale do rio paraíba do sul, RJ**. 100 f. Dissertação (Mestrado em Agronomia) - Universidade Federal Rural do Rio de Janeiro, Seropédica.

Machado RL, Resende AS, Campello EFC (2006) **Recuperação de voçorocas em áreas rurais**. Seropédica: Embrapa Agrobiologia, 63 p.

Mararakanye N, Nethengwe N (2012) Gully Features Extraction using Remote Sensing Techniques. **South African Journal of Geomatics** 1:109-118.

Merschmann LHC (2007) **Classificação probabilística baseada em análise de padrões**. 117 f. Tese (Doutorado em Ciência da Computação) - Universidade Federal Fluminense, Niterói.

Möller M, Birger J, Gidudu A, Glaesser C (2013) A framework for the geometric accuracy assessment of classified objects. **International Journal of Remote Sensing** 34:8685-8698.

Möller M, Lymburner L, Volk M (2007) The comparison index: A tool for assessing the accuracy of image segmentation. **International Journal of Applied Earth Observation and Geoinformation** 9:311-321.

Nascimento AF, Rubim IB, Pereira EGS, Barros RS, Richter M (2013) Classificação da cobertura da terra, utilizando os programas livres: InterIMAGE, WEKA e QuantumGIS. In: XVI Simpósio Brasileiro de Sensoriamento Remoto. **Anais...** Foz do Iguaçu, INPE, 2013, p. 2258-2265.

Novack T (2009) **Classificação da cobertura da terra e do uso do solo urbano utilizando o sistema InterIMAGE e imagens do sensor QuickBird**. 214 f. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

Oliveira LFC de, Martinez MA, Pruski FF, Griebeler NP, Oliveira GC (2005) Rotina computacional para a determinação da velocidade de sedimentação das partículas do solo em suspensão no escoamento superficial. **Engenharia Agrícola** 25:126-136.

Oliveira M (1988) **Física dos solos. Alguns aspectos de interesse agronômico**. 77 f. Universidade de Trás-os-Montes e Alto Douro, Vila Real.

Oliveira MAT, Meis MRM (1985) Relações entre geometria do relevo e formas de erosão linear acelerada (bananal, sp). **Geociências (São Paulo)** 87-99.

D'Oleire-Oltmanns S, Eisank C, Drägut L, Blaschke T (2013) An Object-Based Workflow to Extract Landforms at Multiple Scales From Two Distinct Data Types. **IEEE Geoscience and Remote Sensing Letters** 10:947-951.

D'Oleire-Oltmanns S, Marzloff I, Tiede D, Blaschke T (2014) Detection of Gully-Affected Areas by Applying Object-Based Image Analysis (OBIA) in the Region of Taroudannt, Morocco. **Remote Sensing** 6:8287-8309.

D'Oleire-Oltmanns S (2015) **Gully mapping on multiple scales based on UAV and satellite data**. University of Salzburg and Goethe University Frankfurt, Austria / Germany, p. 263-269.

Pahl M (2008) **Arquitetura de um sistema baseado em conhecimento para a interpretação de dados de sensoriamento remoto de múltiplos sensores**. 95 f. Tese - Universidade de Hannover.

Passo DP (2017) **Desenvolvimento de aplicação para análise geográfica de imagens, baseada em objeto, com a finalidade de identificar automaticamente**

focos erosivos lineares. 185 f. Tese (Doutorado em Geociências) - Universidade de Brasília, Brasília.

Passo DP, Bias ES, Brites RS, Costa GAOP (2013) Uso do sistema InterIMAGE para a identificação de alvos urbanos em imagens do satélite Worldview II. Revista Brasileira de Cartografia 6.

Pereira Júnior RA (2013) **Uso de barreiras físicas em voçoroca e seus efeitos na retenção de sedimentos : um estudo de caso.** 98 f. Dissertação (Mestrado em Geografia) - Universidade Federal de Uberlândia, Uberlândia.

Perroy RL, Bookhagen B, Asner GP, Chadwick OA (2010) Comparison of gully erosion estimates using airborne and ground-based LiDAR on Santa Cruz Island, California. **Geomorphology** 118:288-300.

Persello C, Bruzzone L (2010) A Novel Protocol for Accuracy Assessment in Classification of Very High Resolution Images. **IEEE Transactions on Geoscience and Remote Sensing** 48:1232-1244.

Pinho CMD (2005) **Metodologia de classificação orientada a objetos de uso da terra no espaço intra-urbano a partir de imagens orbitais de alta resolução espacial.** 168 f. Dissertação (Mestrado em Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

Ponzoni FJ, Shimabukuru YE, Kuplich TM (2007) Sensoriamento remoto no estudo da vegetação. São José dos Campos: Parêntese, 127 p.

Quinlan JR (1993) C4.5: Programs for Machine Learning. San Francisco: Morgan Kaufmann Publishers, 302 p.

Radoux J, Bogaert P, Fasbender D, Defourny P (2011) Thematic accuracy assessment of geographic object-based image classification. **International Journal of Geographical Information Science** 25:895-911.

Rahmati O, Tahmasebipour N, Haghizadeh A, Pourghasemi HR, Feizizadeh B (2017) Evaluating the influence of geo-environmental factors on gully erosion in a semi-arid region of Iran: An integrated framework. **Science of The Total Environment** 579:913-927.

Ribeiro BMG, Fonseca LMG, Kux HJH (2011) Avaliação das imagens WorldView-II para o mapeamento da cobertura do solo urbano utilizando o sistema InterIMAGE. In: XV Simpósio Brasileiro de Sensoriamento Remoto. **Anais eletrônicos...**Curitiba, INPE, 2011, p. 0722-0729.

Ribeiro BMG, Fonseca LMG (2013) Urban land cover classification using worldview-2 images and C4.5 algorithm. In: Joint Urban Remote Sensing Event 2013. **Anais...** São Paulo, IEEE, p. 250-253.

Rodrigues TCS (2014) **Classificação da cobertura e do uso da terra com imagens WorldView-2 de setores norte da Ilha do Maranhão por meio do aplicativo InterIMAGE e de mineração de dados.** 87 f. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

Salomão FXT (2005) Controle e prevenção de processos erosivos. Rio de Janeiro: Bertrand Brasil, p. 229-267.

Schäfer MJ, Reichert JM, Reinert DJ, Cassol EA (2001) Erosão em entressulcos e em sulcos sob diferentes preparos e consolidação do solo. **Revista Brasileira de Ciência do Solo**, 25:431-441.

Scholte-Albers DG (2015) **Object-Based Classification of Gullies using UAV-Derived Digital Elevation Models.** 56 f. Thesis - Wageningen University and Research Centre, The Netherlands.

Shit PK, Paira R, Bhunia G, Maiti R (2015) Modeling of potential gully erosion hazard using geo-spatial technology at Garbheta block, West Bengal in India. **Modeling Earth Systems and Environment** 1:2.

Shruthi RBV, Kerle N, Jetten V (2011) Object-based gully feature extraction using high spatial resolution imagery. **Geomorphology** 134:260-268.

Shruthi RBV, Kerle N, Jetten V (2012) Extracting gully features and its dynamics from high spatial resolution imagery using object based image analysis. In: 4th International Conference on Geographic Object-Based Image Analysis. **Anais...** Rio de Janeiro, INPE, p. 7-12.

Shruthi RBV, Kerle N, Jetten V, Stein A (2014) Object-based gully system prediction from medium resolution imagery using Random Forests. **Geomorphology** 216:283-294.

Shruthi RBV, Kerle N, Jetten V, Abdellah L, Machmach I (2015) Quantifying temporal changes in gully erosion areas with object oriented analysis. **Catena** 128:262-277.

Smith L (1993) Investigation of Ephemeral Gullies in Loessial Soils in Mississippi. Smolska E 2007. Development of gullies and sediment fans in last-glacial areas on the example of the Suwałki Lakeland (NE Poland). **Catena** 71:122-131.

Souza UDV, Kux HJH, Johann H (2012) Geobias e mineração de dados na classificação da cobertura do solo urbano em São Luís (MA) com imagens Worldview-2 e o sistema InterIMAGE. **Revista Brasileira de Cartografia**. **Revista Brasileira de Cartografia** 66:433-450.

Takken I, Croke J, Lane P (2008) Thresholds for channel initiation at road drain outlets. **Catena** 75:257-267.

Tebebu TY, Abiy AZ, Zegeye AD, Dahlke HE, Easton ZM, Tilahun SA, Collick AS, Kidnau S, Moges S, Dadgari F, Steenhuis TS (2010) Surface and subsurface flow effect on permanent gully formation and upland erosion near Lake Tana in the northern highlands of Ethiopia. **Hydrology and Earth System Sciences** 14:2207-2217.

Tedesco A, Antunes AFB, Oliani LO (2014) Detection of erosive formation (gully) using hierarchical classification and decision tree. **Geodetic Sciences Bulletin** 20:1005-1026.

Tedesco A (2015) **Gully detection using high resolution images and ALS through decision tree and GEOBIA**. 186 f. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal de Paraná, Curitiba.

Trimble (2012) ECognition Developer 8.8 Reference Book e User Guide. Germany: Definiens.

Valentin C, Poesen J, Li Y (2005) Gully erosion: Impacts, factors and control. **Catena** 63:132-153.

Vandekerckhove L, Poesen J, Oostwoud Wijdenes D, Gyssels G, Beuselinck L, Luna E (2000) Characteristics and controlling factors of bank gullies in two semi-arid mediterranean environments. **Geomorphology** 33:37-58.

VRIELING A (2006) Satellite remote sensing for water erosion assessment: A review. **Catena**, v. 65, p. 2–18.

Vrieling A, Rodrigues SC, Bartholomeus H, Sterk G (2007) Automatic identification of erosion gullies with ASTER imagery in the Brazilian Cerrados. **International Journal of Remote Sensing** 28:2723-2738.

Vu TT (2012) Object-Based Remote Sensing Image Analysis with OSGeo Tools. **Applied Geoinformatics for Society and Environment** 80-84.

Wang J (2010) **Development of geographic image cognition approach for land degradation assessment with hyperion images**. 177 f. Thesis. The Hong Kong Polytechnic University, Hong Kong.

Wang T, He F, Zhang A, Gu L, Wen Y, Jiang W, Shao H (2014) A Quantitative Study of Gully Erosion Based on Object-Oriented Analysis Techniques: A Case Study in Beiyanzikou Catchment of Qixia, Shandong, China. **The Scientific World Journal** 2014:1-11.

Wang R, Zhang S, Pu L, Yang J, Yang C, Chen J, Guan C, Wang Q, Chen D, Fu B, Sang X (2016) Gully Erosion Mapping and Monitoring at Multiple Scales Based on Multi-Source Remote Sensing Data of the Sancha River Catchment, Northeast China. **ISPRS International Journal of Geo-Information** 5:200.

Wells NA, Andriamihaja B (1993) The initiation and growth of gullies in Madagascar: are humans to blame? **Geomorphology** 8:1-46.

Wischmeier WH, Smith DD (1978) Predicting rainfall erosion losses: a guide to conservation planning. Washington: USDA, p. 1-69.

Witten I, Frank E, Hall M (2011) Data Mining: Practical Machine Learning Tools and Techniques. San Francisco: Morgan Kaufmann Publishers, 664 p.

Yang J, He Y, Caspersen J, Jones T (2015) A discrepancy measure for segmentation evaluation from the perspective of object recognition. **ISPRS Journal of Photogrammetry and Remote Sensing** 101:186-192.

Yang J, Li P, He Y (2014) A multi-band approach to unsupervised scale parameter selection for multi-scale image segmentation. **ISPRS Journal of Photogrammetry and Remote Sensing** 94:13-24.

Zhang YJ (1996) A survey on evaluation methods for image segmentation. **Pattern Recognition** 29:1335-1346.

Zhang S, Li F, Li T, Yang J, Bu K, Chang L, Wang W, Yan Y (2015) Remote sensing monitoring of gullies on a regional scale: A case study of Kebai region in Heilongjiang Province, China. **Chinese Geographical Science** 25:602-611.

8 CONSIDERAÇÕES FINAIS

A detecção automática de voçorocas por sensoriamento remoto ainda se mostra uma tarefa desafiadora, haja vista o número de fatores que pode interferir nesse processo. No entanto, essas feições erosivas representam severa degradação ambiental em todo o planeta, demandando estudos que facilitem o seu mapeamento de modo mais eficiente. Assim, o aumento do número de pesquisas que utilizam a GEOBIA para detectar voçorocas possibilita encontrar soluções para as diversas situações, tornando esse método cada vez mais robusto.

O presente estudo, ao focar na avaliação da segmentação, possibilitou a criação de objetos similares às voçorocas no campo. A utilização do índice SEI se mostrou promissora na análise de correspondência dos objetos. Porém, esse índice faz uma generalização abrupta entre os objetos que não atendem ao critério geométrico de 50% de sobreposição bilateral. Sendo assim, recomenda-se a atribuição gradual de pesos correspondentes ao valor do SEI para os objetos que não atendem a condição geométrica, especialmente em situações com pequeno número de objetos a serem avaliados na cena.

Os modelos de detecção de voçorocas por GEOBIA observados na literatura são compostos por muitos parâmetros, dificultando seu entendimento e sua transferibilidade. Por outro lado, os modelos criados empiricamente nesse trabalho continham poucos parâmetros para a classificação dessas feições. Essa simplificação pode ser atribuída à correta da segmentação das voçorocas, preservando as características que separam as voçorocas das demais classes. No entanto, a avaliação da segmentação pelo índice SEI pode consumir muito tempo em situações com elevado número de voçorocas, sendo recomendado a implementação de uma rotina automática para aplicação de sua equação.

É importante destacar que o modelo criado manualmente no *software* InterIMAGE teve auxílio do *software* de mineração de dados, o qual se mostrou mais eficiente na etapa de extração e interpretação dos atributos mais relevantes para a discriminação das voçorocas. Nesse sentido, Souza et al. (2012), ao realizar o mapeamento do solo urbano em São Luís (MA), enfatizam a importância da

associação do *software* de mineração de dados com o *software* InterIMAGE para construção do modelo de classificação por GEOBIA.

A utilização das imagens RapidEye e dados SRTM como dados de entrada, apesar de limitar a detecção de voçorocas pequenas, permitiu a identificação das voçorocas que causam maior degradação ambiental. Assim, os modelos criados podem auxiliar na gestão de áreas prioritárias para contenção dos processos erosivos acelerados. Estudos que buscam detectar a erosão hídrica em estágio inicial devem utilizar dados com resolução submétrica.

A partir da análise do F-measure é possível notar que o modelo combinado conseguiu detectar as voçorocas nas duas áreas de estudos, demonstrando sua transferibilidade. Embora a área de estudo 2 apresente voçorocas maiores que a área 1 não foi necessário alterar os parâmetros que discriminam essas feições, bem como seus limiares. Porém, foi preciso alterar o valor do fator de escala, uma vez que esse parâmetro limita o tamanho dos objetos criados na segmentação. Recomenda-se em estudos futuros a aplicação do modelo criado em outras regiões, com características pedológicas e morfológicas distintas. Dessa forma, será possível obter dados suficientes para uma aplicação em larga escala, de forma rápida e economicamente viável.

Assim como no presente trabalho, alguns autores reportaram limitações no processamento do *software* InterIMAGE, tais como: limitação do tamanho das imagens de entrada (Nascimento et al., 2013); incapacidade de lidar com grande quantidade de segmentos (Passo et al., 2013); incapacidade de processar variáveis relacionadas com vizinhança (Grande et al., 2016). Apesar disso, o InterIMAGE demonstrou ser eficiente para o mapeamento das voçorocas por GEOBIA, uma vez que essas limitações não comprometeram os objetivos do estudo.