

UNIVERSIDADE FEDERAL DE ITAJUBÁ-UNIFEI
MESTRADO EM MEIO AMBIENTE E RECURSOS HÍDRICOS

DELIMITAÇÃO DE VOÇOROCAS POR MEIO DE GEOBIA
(*Geographic Object Based Image Analysis*) E USO DE
PRODUTOS CARTOGRÁFICOS ORIUNDOS DE
AERONAVES REMOTAMENTE PILOTADAS (ARP)

João Edson Costa Ferreira da Silva

Itajubá (MG)

2020

UNIVERSIDADE FEDERAL DE ITAJUBÁ-UNIFEI
MESTRADO EM MEIO AMBIENTE E RECURSOS HÍDRICOS

JOÃO EDSON COSTA FERREIRA DA SILVA

**DELIMITAÇÃO DE VOÇOROCAS POR MEIO DE GEOBIA
(*Geographic Object Based Image Analysis*) E USO DE
PRODUTOS CARTOGRÁFICOS ORIUNDOS DE
AERONAVES REMOTAMENTE PILOTADAS (ARP)**

Dissertação submetida ao Programa de Pós Graduação em Meio Ambiente e Recursos Hídricos como parte dos requisitos para obtenção do título de Mestre em Ciências em Meio Ambiente e Recursos Hídricos. Área de concentração: Meio Ambiente e Recursos Hídricos.

Orientadora: Prof. Dra. Nívea Adriana Dias Pons - UNIFEI

Itajubá (MG)

2020

UNIVERSIDADE FEDERAL DE ITAJUBÁ
INSTITUTO DE RECURSOS NATURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM NÍVEL DE MESTRADO EM MEIO
AMBIENTE E RECURSOS HÍDRICOS

FOLHA DE APROVAÇÃO

Autor: João Edson Costa Ferreira da Silva

Título: **Delimitação de voçorocas por meio de Geobia (*Geographic Object Based Image Analysis*) e uso de produtos cartográficos oriundos de aeronaves remotamente pilotadas (ARP)**

Dissertação apresentada em 13 de Março de 2020.

À Banca Examinadora composta pelos seguintes membros:

Profa. Dra. Nívea Adriana Dias Pons (orientadora)
UNIFEI – Universidade Federal de Itajubá

Profa. Samara Calçado de Azevedo
UNIFEI – Universidade Federal de Itajubá

Profa. Dra. Camila de Souza Anjos Lacerda
IFSULDEMINAS – Campus Inconfidentes



QUADRO DEMONSTRATIVO DE APURAÇÃO

Defesa de Dissertação de Mestrado em Meio Ambiente e Recursos Hídricos

Título do trabalho: "Delimitação de Voçorocas, por meio de GEOBIA (Geographic Object Based Image Analysis) e uso de produtos cartográficos oriundos de Aeronaves Remotamente Pilotadas (ARP)"

Autor(a): João Edson Costa Ferreira da Silva

JULGAMENTO (PRESENCIAL)

Examinador(a)	Nome Completo	Conceito
1 ^{o(a)}	Camila de Souza Anjos Lacerda	Aprovado
2 ^{o(a)}	Samara Calçado de Azevedo	Aprovado
3 ^{o(a)}	Nívea Adriana Dias Pons	Aprovado

Conforme Art. 57, da Norma de Programas de Pós-Graduação da Universidade Federal de Itajubá:

- (1) O trabalho será considerado aprovado se todos os examinadores atribuírem conceito "A";
 - (2) O trabalho será considerado reprovado se for atribuído pelo menos dois conceitos "R";
 - (3) O trabalho será considerado insuficiente (I) se for atribuído um único conceito "R".
- No caso (3), a Comissão Examinadora definirá como avaliar a nova versão da dissertação, que deverá ser submetida novamente num período de até 3 (três) meses.

Resultado Final: A.

Conceito Final: APROVADO.

*Responder com "A", "R" ou "I".

*Responder com "Aprovado", "Reprovado" ou "Insuficiente".

Observações:

Itajubá, 13 de março de 2020.

Camila de Souza Anjos Lacerda

1^{o(a)} Examinador(a) - IFSULDEMINAS (Campus Inconfidentes)

Samara Calçado de Azevedo

2^{o(a)} Examinador(a) - UNIFEI



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE ITAJUBÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO



Página 2 de 2

Nívea Adriana Dias Pons

3^o(a) Examinador(a) - Orientador(a) - UNIFEI

Dedico este trabalho a minha Avó Georgina da Costa, pelo Amor que jamais faltara.
À minha família, meus familiares e amigos.

“Existe um caminho que vai dos olhos ao coração sem passar pelo intelecto”.

(G. K. Chesterton)

AGRADECIMENTOS

SENHOR, vós que sois o dono de tudo. Está pregada a minha Vida na tua cruz. Que esta seja mais uma obra ao teu favor, do que a mim mesmo. Senhor, mesmo com todas as minhas limitações, ofereço-a.

Agradeço a Deus Pai, filho e Espírito Santo, por fitar os meus olhos e me conduzir em todas as coisas.

Agradeço a minha orientadora Nívea pela paciência e o amor que ofereceu a mim por meio das oportunidades e direcionamentos. Com certeza sem o seu apoio não conseguiria chegar aqui.

Agradeço a Professora Camila por ser canal de graça e conhecimento em minha vida. A cada dia mais se torna uma inspiração para mim.

Expresso minha alegria e gratidão por minha Família e meus Familiares. Aos meus avós que me deram um Amor intacto e incorruptível, meu mais sincero agradecimento, nunca conseguirei pagar o que me fizeram. A minha Mãe, minha irmã Yale e meu irmão Pedro por ser minha família. Aos meus Tios (José Geraldo, Zezé e Carlinhos) e Tia Tuca, agradeço pelo apoio e educação. Aos meus afilhados Luiz Miguel e Lorenzo, e meu sobrinho Mateus, agradeço por serem alegria nos tempos difíceis.

Aos meus amigos e amigas Letícia, Mariana, Winne, Camila Welerson, Rafael, Murilo, Talita, Bruna, Ana Flávia, Lígia, agradeço pelas boas conversas e companhias.

Ao GOU São Bento por rezarem por mim.

Agradeço a UNIFEI que me permitiu viver momentos maravilhosos nesse período. Todos professores e funcionários, em especial Rogério Melloni, Dani, Ana Lúcia e Marcelo.

Agradeço a FAPEMIG pelo apoio fundamental para a minha pesquisa.

Deixo aqui meus especiais agradecimentos a minhas amigas que me ajudaram nessa dissertação, Thais Costa e Thais Gonçalves, vocês também me inspiram.

A minha Comunidade Javé Nissi, agradeço por rezarem por mim e serem suporte para a minha chegada até o céu.

A minha amiga, namorada, Daiane, que DEUS permitiu que vivesse o tempo do conhecimento, por rezar por mim e ser suporte para o meu crescimento.

Agradeço a UNIFEI por me permitir viver tão intensamente o aprendizado no Mestrado. A Itajubá MG, sempre estará no meu coração.

Agradeço ao IFSULDEMINAS – Campus Inconfidente, pela minha formação e capacitação, permitindo que neste tempo atual me tornasse Professor.

Deixo nessas linhas meu coração, pois uma dissertação é algo que também vive dentro de nós.

A todos muito obrigado!

RESUMO

Nos tempos atuais, com as medidas ambientais em evidência, é comum a discussão sobre melhores maneiras de obter informações cartográficas sobre as áreas degradadas. Essas informações já são de suma importância para a efetividade de alguns programas já propostos no Brasil, como o Cadastro Ambiental Rural (CAR) e o Programa de Recuperação Ambiental (PRA). Quando se trata de áreas degradadas destacam-se os fatores diversos que contribuem com a degradação, sobretudo a degradação do solo. As degradações do solo quando em último estado geram voçorocas, as quais apresentam diversos prejuízos à natureza, pois possuem estado irreversível, sendo possível somente sua recuperação parcial. O monitoramento destas áreas, bem como informações sobre as mesmas, é de suma importância para que se possa garantir o controle e definir os métodos de conservação destas áreas. Sob esta problemática, este trabalho visa avaliar a eficiência de um procedimento de classificação, orientada, semiautomática (GEOBIA) em produtos cartográficos produzidos por Aeronaves Remotamente Pilotadas (ARP) para a delimitação de voçorocas. A utilização dos produtos cartográficos oriundos de ARP (Modelo Digital de Elevação e Ortoimagem Digital) se justifica devido ao baixo custo da ferramenta, bem como a potencialidade planimétrica e altimétrica, que esses produtos tem apresentado; um outro fator de destaque é a informação remota através destes produtos que garante maior segurança em relação aos métodos convencionais de obtenção de informações. O trabalho aborda a combinação da mineração de dados e GEOBIA, como técnicas auxiliares nos processos de delimitação de voçorocas. Os procedimentos foram realizados em duas áreas de estudo, ambas situadas no município de Itajubá-MG. Nestas áreas foram definidos alguns pontos de controle e checagem para a classificação dos produtos cartográficos em relação ao Padrão de Exatidão Cartográfico Digital (PEC-PCD). Os produtos apresentaram classe A, para a escala 1/2.000. Foram determinados alguns parâmetros de segmentação para que se formassem segmentos fidedignos para cada área de estudo em específico, em seguida determinaram-se os atributos mais relevantes para a classificação e confecção da árvore de decisão de cada área. Na confecção da árvore de decisão utilizou-se o algoritmo C 4.5. Os resultados foram satisfatórios a níveis de precisão (índice Kappa entre 0,88 e 0,92), tornando possível que as técnicas utilizadas em produtos cartográficos oriundos de ARP sejam uma ferramenta para delimitação de áreas degradadas do tipo voçoroca.

Palavras – chave: Sensoriamento Remoto. Áreas degradadas. Segmentação. Árvore de decisão. Voçoroca.

ABSTRACT

Nowadays, with environmental measures in evidence, it is common to discuss the best ways to obtain cartographic information about degraded areas. This information is of paramount importance for the effectiveness of some programs already proposed in Brazil, such as the Rural Environmental Registry (RER) and the Environmental Recovery Program (ERP). When it comes to degraded areas, there are several factors that contribute to degradation, especially soil degradation. Degradations of the soil when in the last state generate gullies, which present several damages to nature, as they have an irreversible state, being possible only their partial recovery. The monitoring of these areas, as well as information about them, is of the utmost importance to ensure control and define the conservation methods of these areas. Under this problem, this work aims to evaluate the efficiency of a classification procedure, oriented, semi-automatic (GEOBIA) in cartographic products produced by Remote Piloted Aircraft (RPA) for the delimitation of gullies. The use of cartographic products from ARP (Digital Elevation Model and Digital Orthophoto), is justified due to the low cost of the tool, as well as the Planimetric and Altimetric potential that these products have presented; Another important factor is the remote information through these products, which guarantees greater security in relation to conventional methods of obtaining information. The work addresses the combination of data mining and GEOBIA, as auxiliary techniques in gully delimitation processes. The Procedures were carried out in two study areas, both located in the municipality of Itajubá-MG. In these areas, some control and checking points were defined for the classification of cartographic products in relation to the Digital Cartographic Accuracy Standard (DCAS). The products presented class A, for the 1 / 2,000 scale. Some segmentation parameters were determined to form reliable segments for each specific study area, then the most relevant attributes were determined for the classification and construction of the decision tree for each area. In making the decision tree, the C 4.5 algorithm was used. The results were satisfactory at levels of precision (Kappa index between 0.89 and 0.92), making it possible for the techniques used in cartographic products from ARP to be a tool for delimiting degraded areas of the gully erosion.

Keywords: Remote sensing. Degraded areas. Segmentation. Decision tree. Gully erosion.

LISTA DE SIGLAS

CAR – Cadastro Ambiental Rural

COO – Classificação Orientada a Objeto

DCAS – Digital Cartographic Accuracy Standard

DP – Desvio Padrão

EM – Erro Médio

EP – Erro Padrão

EQM - Erro Quadrático Médio

ERP – Environmental Recovery Program

ET-ADGV - Especificação Técnica para Aquisição de Dados Geoespaciais Vetoriais

ET-PCDG - Especificações Técnicas dos Produtos dos Conjuntos de Dados Geoespaciais

FOV - Field of View

GEOBIA - Geographic Object Based Image Analysis

GNSS - Global Navigation Satellite System

GSD - Ground Sample Distance

MDE – Modelo Digital de Elevação

MDT – Modelo Digital do Terreno

NIR - NearInfraRed

PCD – Padrão Cartográfico Digital

PE – Parâmetro de Escala

PEC - Padrão de Exatidão Cartográfico

PH - Parâmetro de Heterogeneidade

PPP – Posicionamento por Ponto Preciso

PRA – Programa de Recuperação Ambiental

RER – Rural Environmental Registry

RGB – Red, Green, Blue

RPA - Remote Piloted Aircraft

RTK - Real Time Kinematic

UTM - Universal Transversa de Mercator

LISTA DE FIGURAS

Figura 1. Evolução de sulcos e ravinas para voçorocas.	22
Figura 2. Voçoroca.	22
Figura 3. Aeronaves remotamente pilotadas (ARP). (A) Drone.(B) Avião de asa fixa.	26
Figura 4. Representação gráfica de uma árvore de decisão.	31
Figura 5. Mapa de localização da Área de Estudo 1.	38
Figura 6. Mapa de localização da área de Estudo 2.	38
Figura 7. a) Voçoroca na área de estudo 1 e b) Voçoroca na área de estudo 2.	39
Figura 8. Tipo de solo da Área de Estudo 1.	40
Figura 9. Tipo de solo da Área de Estudo 2.	40
Figura 10. Fluxograma – Método.	41
Figura 11. Equipamento ARP utilizado no estudo (ARP Phantom4).	43
Figura 12. Cálculo GSD.	44
Figura 13. Elementos artificiais utilizados como pontos de controle.	45
Figura 14. Amostras coletadas - Área de Estudo 1.	55
Figura 15. Amostras coletadas - Área de Estudo 2.	55
Figura 16. Ortoimagem Digital - Área de Estudo 1	59
Figura 17. Ortoimagem Digital - Área de Estudo 2	60
Figura 18. Ortoimagem Digital - Área de Estudo 1	61
Figura 19. Ortoimagem Digital - Área de Estudo 1	62
Figura 20. Segmentação multirresolução - FE= 10 e Spectral Diference = 1 - Área de Estudo 01.	64
Figura 21. Segmentação multirresolução - FE= 10 e Spectral Diference = 1 - Área 02.	65
Figura 22. Classificação temática Área de Estudo 01.	73
Figura 23. Classificação temática da Área de Estudo 2.	73

LISTA DE TABELAS

Tabela 1. Padrão de exatidão cartográfica da planimetria dos produtos cartográficos digitais.	37
Tabela 2. Padrão de exatidão cartográfica altimétrica dos pontos cotados e do MDT, MDE e MDS para a produção de produtos cartográficos digitais.	37
Tabela 3. Principais características da ARP utilizada no estudo (ARP Phantom 4) em comparação com outras aeronaves.	43
Tabela 4. Parâmetros de voo estabelecidos para a Área de estudo 1 e 2.	44
Tabela 5. Coordenadas coletadas dos pontos de controle das áreas de estudo.	45
Tabela 6. Atributos submetidos à mineração de dados para as áreas 1 e 2.	53
Tabela 7. Atributos submetidos à mineração de dados para as áreas 1 e 2.	54
Tabela 8. Algoritmos utilizados para a Seleção de Atributos - WEKA 3.8.	56
Tabela 9. Classificação dos produtos cartográficos e estatísticas descritivas - Área de Estudo 1.	63
Tabela 10. Classificação dos produtos cartográficos e estatísticas descritivas - Área de Estudo 2.	63
Tabela 11. Atributos determinados para a Área de Estudo 01 (<i>Classifier Attribute Eval</i>).	67
Tabela 12. Atributos determinados para a Área de Estudo 01 (<i>InfoGainAttributeEval</i>).	67
Tabela 13. Atributos determinados para a Área de Estudo 01 (<i>Principal Components</i>).	68
Tabela 14. Atributos determinados para a Área de Estudo 02 (<i>Classifier Attribute Eval</i>).	69
Tabela 15. Atributos determinados para a Área de Estudo 02 (<i>Info Gain Attribute Eval</i>).	69
Tabela 16. Atributos determinados para a Área de Estudo 02 (<i>Principal componets</i>).	70
Tabela 17. Resultados das árvores de decisão das Áreas de Estudo.	72
Tabela 18. Matriz de confusão Área de Estudo 01.	74
Tabela 19. Matriz de confusão Área de Estudo 02.	74

SUMÁRIO

1	INTRODUÇÃO	16
2	OBJETIVOS.....	18
2.1	Objetivo geral	18
2.2	Objetivos específicos	18
3	FUNDAMENTAÇÃO TEÓRICA	19
3.1	Degradação do solo e processos erosivos	19
3.2	Voçorocas	21
3.2.1.	Contextualização geral	21
3.2.2.	Monitoramento: Sensoriamento remoto e Geoprocessamento	23
3.3	Aeronaves Remotamente Pilotadas (ARP).....	26
3.3.1	Produtos cartográficos provenientes de Aeronaves Remotamente Pilotadas (ARP)	26
3.4	Segmentação de imagens	27
3.4.1	Segmentação multirresolução e por diferença espectral (<i>Spectral Difference</i>)	28
3.5	Mineração de dados (<i>Data mining</i>)	30
3.5.1	Árvores de decisão	30
3.5.2	Extração de atributos.....	31
3.5.3	Seleção de atributos.....	32
3.6	Classificação de imagens	33
3.6.1	Classificação Orientada a Objeto (GEOBIA)	34
3.7	Padrão de exatidão cartográfico e padrão de exatidão cartográfico digital (PEC-PCD)	35
4	METODOLOGIA	38
4.1	Caracterização da área de estudo	38
4.2	MÉTODO	41
4.2.1	Levantamento dos dados: ARP, pontos de controle e plano de vôo	42
4.2.2	Processamento dos dados e Confecção dos produtos cartográficos.....	46
4.2.3	Avaliação dos produtos cartográficos em relação ao PCD (Padrão Cartográfico Digital).....	46
4.2.4	Segmentação e determinação dos objetos imagens.....	48
4.2.5	Planejamento da classificação	49
4.2.6	Extração de Atributos.....	52
4.2.7	Seleção de atributos por mineração de dados.....	56
4.2.8	Árvore de decisão.....	57

4.2.9	Classificação temática e avaliação da classificação temática	57
5	RESULTADOS E DISCUSSÕES	58
5.1	Construção e classificação dos produtos cartográficos em relação ao PEC e PCD	58
5.2	Geração de objetos a partir de parâmetros de segmentação	64
5.3	Mineração de dados (Árvores de decisão e seleção de atributos).....	65
5.4	Classificação Temática	72
6	CONSIDERAÇÕES FINAIS	77
7	REFERÊNCIAS	79
	APÊNDICE 1 – Árvores de Decisão.....	87

1 INTRODUÇÃO

A degradação do solo é caracterizada como um problema mundial, tendo em vista que abrange diversos aspectos que se estendem desde as questões econômicas, como o uso do solo na produção agrosilvopastoril, até questões sociais, como a construção de casas em locais irregulares. Logo, o estudo das áreas que foram alvo de degradação é considerado imprescindível quando se trata de planejamento territorial.

Quando levado em consideração os aspectos ambientais das áreas degradadas, é interessante destacar que as mesmas podem atingir estados irreversíveis em termos de recuperação do solo. Os fatores que levam à degradação do solo podem ser ligeiramente resumidos pela poluição do solo (aspectos físico-químico) ou pela erosão, sendo este, um grande causador das incisões denominadas voçorocas.

O levantamento de informações sobre voçorocas se faz necessário para o controle ambiental e, junto aos avanços tecnológicos utilizados para este fim, é esperada a realização de um levantamento de forma remota e precisa. Tais informações não devem se resumir apenas às características geográficas das voçorocas, como também devem fornecer subsídios para o processo de monitoramento e mapeamento das áreas.

O uso dos produtos cartográficos derivados de Aeronaves Remotamente Pilotadas (ARP), combinados ao Sensoriamento Remoto, tem se mostrado como uma alternativa para sanar as necessidades do levantamento de informações sobre as voçorocas. A tecnologia se apresenta como uma ferramenta de baixo custo em relação às outras fontes de informação, além disso, a precisão dos produtos gerados e a iteratividade computacional que o uso da ferramenta permite realizar é motivo de destaque quando utilizada para estes fins.

A automatização dos processos de aquisição de informações pode ser dada nas esferas da coleta de informações em campo e do processamento dos dados. A caracterização e delimitação das voçorocas utilizando ARP são geradas de formas semiautomática utilizando o procedimento denominado *Geographic Object Based Image Analysis* (GEOBIA). Junto desse processo, destaca-se a segmentação de imagens e a mineração de dados, como etapas fundamentais do procedimento. O uso dessas ferramentas combinadas é visto em alguns estudos como Doleire-oltmanns et al. (2012) Tedesco (2015), Shruthi et al. (2015), Bertalan e TúrieSzabó (2016).

Diante da eficiência da tecnologia ARP para diversos fins e a necessidade de um maior conhecimento sobre a degradação do solo, este estudo foi realizado com a finalidade de

apresentar um panorama sobre o uso dos produtos cartográficos oriundos de ARP para a delimitação de voçorocas, através de um procedimento semiautomático com o uso da GEOBIA e mineração de dados.

2 OBJETIVOS

2.1 Objetivo geral

- Avaliar a eficiência de um procedimento de classificação orientada, semiautomática (GEOBIA) e de mineração de dados, em produtos cartográficos oriundos de Aeronaves Remotamente Pilotadas (ARP) para a delimitação de voçorocas.

2.2 Objetivos específicos

- Gerar os produtos cartográficos a partir de voo aerofotogramétrico, com Aeronaves Remotamente Pilotadas (ARP);
- Avaliar o Padrão de Exatidão Cartográfico (PEC) dos produtos cartográficos oriundos por Aeronaves Remotamente Pilotadas (ARP);
- Definir um conjunto de parâmetros de segmentação, que permitam a identificação do elemento (objeto) voçoroca;
- Extrair atributos, sobre os produtos cartográficos oriundos de ARP;
- Determinar por meio de mineração de dados (seleção de atributos e árvores de decisão), uma regra de classificação ótima para a determinação do elemento voçoroca;
- Avaliar a qualidade da classificação das imagens, realizadas a partir das árvores de decisão.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 Degradação do solo e processos erosivos

O solo é um recurso natural formado a partir de adições, perdas, transformações, transporte e remanejamento de partes rochosas da superfície terrestre (OLIVEIRA et al., 2011). Segundo Kampft e Curi (2012), o solo é um corpo formado na superfície terrestre a partir das rochas, por meio do processo de intemperismo, que pode ser resumido pela fragmentação e decomposição do material de origem por meio de fatores ambientais como o clima, relevo, organismos dentre outros.

Assim como os demais recursos naturais, o solo tem sofrido diversos impactos ambientais negativos, sendo motivo de preocupação ambiental. A degradação do solo é capaz de influenciar o equilíbrio do ecossistema, além disso, pode levar a problemas de disponibilidade de água e queda dos níveis de produção agropecuária, comprometendo a economia global e a qualidade de vida da população (OLIVEIRA et al., 2011; SARAIVA, SILVA, SANTOS, 2016).

Lal (2001) afirma que a erosão do solo contribui diretamente com degradação do solo, tendo em vista que junto do transporte de partículas, normalmente há a retirada de matéria orgânica e outros minerais. O autor ainda expõe em seu estudo, que o enfraquecimento das estruturas provem do declínio da qualidade do solo.

Oliveira et al. (2011) destacam que o uso do solo sem levar em consideração aspectos como a composição químico-física e condições de relevo, leva à existência de solos improdutivos e degradados e, conseqüentemente, a ocorrência de sérios problemas ambientais e sociais.

Diante deste contexto, é possível afirmar que a degradação do solo está intimamente ligada às atividades antrópicas, as quais quando realizadas sem medidas de conservação do solo, provocam diversas alterações no mesmo, sendo os processos erosivos destacados na literatura como a consequência da degradação mais preocupante (SILVA, 2016), uma vez que é considerada uma grande ameaça à sustentabilidade dos ecossistemas naturais (LAL, 2001; DLAMINIET et al., 2011).

A erosão é um processo geológico, responsável pela remoção e transporte de partículas do solo, sendo influenciada por fatores naturais como a chuva, e intensificada em função do uso da terra (GIOVANINI JUNIOR, 2019). Para Lal (2001), a erosão se dá por meio de três principais processos: deslocamento, transporte e deposição do solo.

Os padrões de desenvolvimento da erosão são diversos e complexos, sendo considerados como os principais fatores de influência para sua formação: a erosividade da chuva, erodibilidade dos solos, topografia e o uso e manejo dos solos (SARAIVA, SILVA, SANTOS, 2016).

Os processos erosivos estão relacionados a agentes causadores, sendo estes o vento, a água e a gravidade, os quais levam à ocorrência de diversos tipos de erosão, como descrito no Quadro 1, a seguir.

Quadro 1 - Tipos de erosão e agentes causadores.

Agente causador	Aspecto causador	Tipo de erosão	
Vento		Eólica	
Água	Chuva	Impacto das gotas no solo	
	Escoamento	Superficial	Sulcos Ravinas Voçorocas Canais fluviais
		Subsuperficial	Condutores subterrâneos
	Oceano	Costeira	
	Glacial		
Gravidade	Movimento de massa	Avalanche Escorregamento Solifluxão Rastejo	

Fonte: Adaptado de Giovanini Junior (2019).

A água é considerada o principal agente causador de erosão, de acordo com Bertoni e Lombardi Neto (2010), tendo destaque ainda maior a ação das chuvas, que provocam a erodibilidade do solo, que é o potencial da chuva provocar erosão (CONCEIÇÃO, 2014). Segundo Giovanini Junior (2019), o principal fator na erosão hídrica ocasionada pela chuva é devido ao movimento horizontal e vertical da água.

Durante e após as chuvas, as forças de impacto das gotas sobre o solo e o escoamento superficial e subsuperficial promovem a quebra dos agregados do solo, levando ao desprendimento das partículas (FLAUZINO, 2012) e, em sequência, a força das águas induz o desprendimento das partículas do solo (ZUQUETTE, CARVALHO; YAMANOUTH, 2007).

Em especial, o escoamento superficial em áreas onde não há recobrimento do solo leva ao surgimento de sulcos, ravinas e voçorocas que surgem em função das linhas de escoamento superficial, resultando em incisões na superfície do solo (LOUREIRO; GUERRA, 2012).

A erosão hídrica não é considerada uma problemática apenas no que se refere à degradação do solo de forma isolada, uma vez que durante este processo, os nutrientes presentes no solo são arrastados junto das partículas de solo, atingindo corpos d'água, causando assoreamento e até mesmo a eutrofização dos recursos hídricos (CONCEIÇÃO, 2014).

É interessante salientar que a erosão é um processo natural, onde há perda de solo e transporte de sedimentos contínuos, que acontece de forma lenta ao longo do tempo (CONCEIÇÃO, 2014). No entanto, este processo tem sido intensificado pela ação antrópica, levando à erosão acelerada. Na erosão acelerada há o rompimento do equilíbrio natural da formação dos solos, ocorrendo uma intensificação da degradação que comumente é realizada pelo ser humano, sendo o uso e a ocupação do solo os principais aspectos capazes de influenciar na aceleração dos processos erosivos (CONCEIÇÃO, 2014; TEDESCO, 2015).

Diante disso, estudos que busquem compreender os processos erosivos e estabelecer formas de identificar e conter, as voçorocas, são essenciais para a melhoria da manutenção da qualidade ambiental no que se refere ao solo (SARAIVA; SILVA; SANTOS, 2016).

3.2 Voçorocas

3.2.1. Contextualização geral

O escoamento superficial, ao ganhar maior volume, tende a se concentrar em pequenas depressões do relevo, criando sulcos que deixam marcas perceptíveis nas encostas e quando não estabilizados, tendem a evoluir para feições maiores denominadas como ravinas (SOUSA; FERREIRA, 2017).

Em casos em que há a existência das ravinas associadas ao intenso desmatamento, falta de práticas conservacionistas do uso do solo, pisoteio de gado, entre outras atividades que se caracterizam como fonte de degradação do solo, há o alargamento das ravinas, levando ao surgimento das voçorocas (TSCHIEDEL et al., 2018), como pode ser observado na Figura 1. De acordo com Sousa e Ferreira (2017), as voçorocas correspondem ao estágio mais avançado dos processos erosivos de origem hídrica.

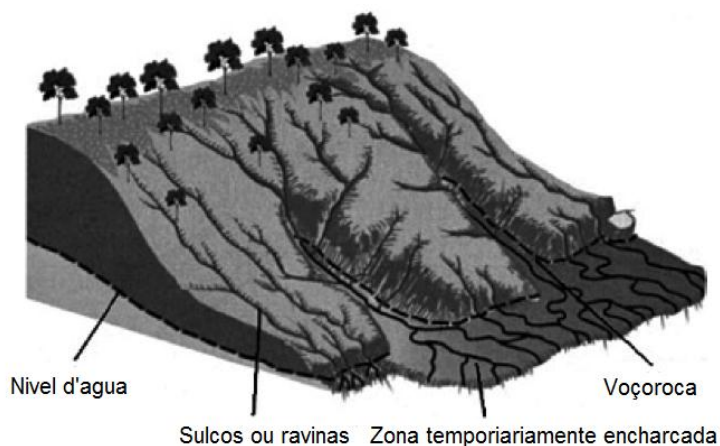


Figura 1. Evolução de sulcos e ravinas para voçorocas.

Fonte: Teixeira (2000).

Desta forma, pode-se dizer que as voçorocas são consequências dos processos erosivos primários, sulcos e ravinas, apresentadas na forma de uma ampliação dos processos erosivos e formando grandes cavidades em extensão e profundidade (ARAUJO; ALMEIDA; GUERRA, 2005). Segundo Leal e Rodrigues (2011), a perda da cobertura vegetal gerada em função das atividades antrópicas, principalmente do agronegócio, associada às chuvas intensas, resultam em condições ideais para a evolução dos processos erosivos, originando as voçorocas.

Guerra et al. (2005) afirmam que ravinas e voçorocas podem ser consideradas como incisões que resultam da tendência de sistemas naturais de atingir um estado de equilíbrio entre energia disponível e eficiência do sistema em dissipar energia. Para o autor, o que diferencia ravinas e voçorocas são questões dimensionais, sendo que as ravinas são caracterizadas como incisões de até 50 centímetros de largura e profundidade, e as situações que apresentam dimensões superiores a estas são consideradas como voçorocas (Figura 2).



Figura 2. Voçoroca.

Fonte: Domínio Público (2019)

As voçorocas podem apresentar formas geométricas variadas, as quais estão relacionadas com a declividade, substrato litológico, pedológico, tipo de solo, escoamento superficial dentre outros, podendo assumir formas de coração, e outras já são profundas e extensas, como garganta (SOUSA; FERREIRA, 2017).

3.2.2. Monitoramento: Sensoriamento remoto e Geoprocessamento

A definição de sensoriamento remoto pode ser vista em Elachi (1987) como sendo a ciência que obtém a informação de um objeto sem obter contato físico com o mesmo. De forma abrangente, Novo (2010) diz que o sensoriamento remoto é a utilização conjunta de sensores para processamento de dados, ou seja, é dado pela transmissão de dados colocados a bordo de aeronaves de diferentes formas ou outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta Terra, a partir das interações entre a radiação eletromagnética e as substâncias que compõem a superfície.

Introduzindo as definições apresentadas por Elachi (1987) e Novo (2010), no contexto do monitoramento, é possível prever êxito na determinação remota de informações sobre o elemento voçoroca.

Considerando os aspectos ambientais que contribuem com a formação de voçorocas, como, ausência de cobertura vegetal, cultivo de monocultura sobre em tudo em áreas de preservação permanente, entre outros; torna-se evidente que esta situação se trata de uma problemática ambiental, no que diz respeito à conservação do solo. Sendo assim, o monitoramento destas incisões existentes no solo é de extrema relevância para o sucesso das técnicas de recuperação, uma vez que são capazes de oferecer informações para que projetos sejam elaborados e os efeitos secundários da existência das voçorocas sejam erradicados (TSCHIEDEL et al., 2018).

O monitoramento das voçorocas tem sido amplamente difundido por meio de estudos científicos, adotando o uso de geotecnologias como de Tedesco (2015) e Tschiedel et al. (2018). As técnicas desenvolvidas com a finalidade de monitorar os processos erosivos consideram uma diversidade de aspectos capazes de influenciar na existência e evolução das voçorocas como uso do solo, condições climáticas, entre outros fatores (TEDESCO, 2015).

A grande maioria das técnicas estabelecidas nos últimos anos para monitorar os processos erosivos estão voltadas para o mapeamento das áreas onde há pontos de degradação, o que, segundo Shruthi et al. (2015), é essencial para a implementação de medidas de conservação do solo.

O monitoramento das voçorocas pode se dar por meio de métodos indiretos, como o mapeamento das áreas onde há constatação de processos erosivos, trazendo um novo olhar sobre como realizar o monitoramento destas áreas. Este método de obtenção de informações é capaz de otimizar o processo de avaliação das voçorocas, uma vez que até então, o controle da evolução das voçorocas pelo método tradicional é realizado por meio de estaqueamentos ao redor da voçoroca com uma distância relativa uma das outras, entre 10 ou 20 metros, a depender do tamanho da voçoroca em estudo. Em seguida, é realizado um croqui da área, estabelecendo as distâncias de cada estaca até a borda da voçoroca. Ao longo do tempo, esta técnica é repetida, buscando verificar se houve aumento das voçorocas, demandando muito tempo e mão-de-obra em sua execução (BRASIL et al., 2010).

As técnicas de mapeamento podem ser realizadas através de levantamentos topográficos utilizando estação total, acompanhados ou não de receptores GNSS (*Global Navigation Satellite System*) como mencionado por Tedesco (2015) ou até mesmo pelo uso de ARP que, por meio de técnicas de aerofotogrametria, pode contribuir com a obtenção de dados topográficos a partir de imagens aéreas, permitindo a verificação de pontos onde há ocorrência de voçoroca e sua evolução ao longo do tempo (TSCHIEDEL et al., 2018). Os estudos de Alves (2007) e Gregório, Alves e Silva (2014), mostram a eficiência do sensoriamento remoto no mapeamento de informações sobre diferentes tipos de processos erosivos.

Longhitano et al. (2016) afirmam que a classificação temática de áreas degradadas são de extrema relevância para o contexto de planejamento ambiental, tendo em vista que até tempo atrás, os critérios de monitoramento de voçorocas era baseado unicamente por inspeções visuais, produzindo fotografias e relatórios. Já com o uso do geoprocessamento, é possível obter informações precisas não somente em relação ao dimensionamento da voçoroca, como também sobre o contexto da microrregião onde a mesma está inserida.

Para Ercole (2019) a compreensão de uma diversidade de aspectos que estão ligados ao processo erosivo são fundamentais para determinar técnicas de recuperação eficientes, afinal, para que o técnico escolha a melhor técnica de recuperação é necessário compreender aspectos como presença de vegetação, proximidade com a malha urbana, entre outros itens que estão diretamente relacionados com o uso e ocupação do solo.

Silva (2016) ainda destaca que os mapas temáticos voltados para a análise da degradação do solo é uma ferramenta capaz de auxiliar os projetos ambientais. Além disso, trata-se de produtos obtidos de forma rápida e que carregam consigo informações diversas sobre a área que fora alvo de degradação.

De acordo com Leal e Rodrigues (2011) as técnicas de mapeamento das voçorocas através das geotecnologias se apresentam como uma alternativa viável e tem grande destaque quando comparadas com o método tradicional. Além disso, tais técnicas de monitoramento proporcionam a aquisição de informações com agilidade e precisão.

É importante salientar que tal trabalho é considerado desafiador devido às características morfológicas de aparência heterogênea de voçorocas, ou seja, não existe um padrão entre a existência e evolução quando se fala de processos erosivos (POESEN et al., 2003).

O conjunto de técnicas que permitem estudar, adquirir, processar e analisar as informações provenientes do sensoriamento remoto é o geoprocessamento. Segundo Rosa (2013), o geoprocessamento pode ser definido como o conjunto de tecnologias destinadas à coleta e tratamento de informações espaciais, assim como o desenvolvimento de novos sistemas e aplicações, com diferentes níveis de sofisticação.

Zaidan (2017) complementa o conceito de geoprocessamento, dizendo que se trata de técnicas e métodos teóricos e computacionais relacionados com a coleta, entrada, armazenamento, tratamento e processamento de dados, a fim de gerar novos dados e ou informações espaciais ou georreferenciadas.

O uso do geoprocessamento tem ganhado cada vez mais destaque em função de ser considerado uma ferramenta capaz de auxiliar a manipulação de dados provenientes da ciência sensoriamento remoto. Além disso, o geoprocessamento permite a interação computacional entre os dados obtidos, permitindo rapidez na aquisição e no gerenciamento de informações. Também se deve destacar que o geoprocessamento traz benefícios como a redução do tempo e agilidade na disponibilidade das informações quando adotadas as tecnologias de informação junto de aeronaves (IRIZARRY; GHEISARI; WALKER, 2012).

A técnica de geoprocessamento tem sido amplamente utilizada para diversos fins, incluindo a obtenção de informações sobre áreas degradadas (LONGHITANO, 2010), em especial, o uso de Aeronaves Remotamente Pilotadas (ARP ou, do inglês, RPA) são utilizadas na aquisição de informações diversas sobre estas áreas (TSCHIEDEL et al., 2018).

3.3 Aeronaves Remotamente Pilotadas (ARP)

Entende-se como ARP toda aeronave não tripulada pilotada a partir de uma estação de pilotagem remota com finalidade diversa, incluindo drones e aviões de asa fixa (Figura 3), usados para fotogrametria (AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, 2018).




Figura 3. Aeronaves Remotamente Pilotadas (ARP). (A) Drone.(B) Avião de asa fixa.
Fonte: Domínio Público (2019)

As ARP com câmeras a bordo são ferramentas que geram produtos cartográficos da ordem de precisão de centímetros. Diferente das imagens de satélite, as ARP possuem uma resolução temporal que depende somente do operador e isto facilita quando a intenção é realizar um mapeamento ou monitoramento. A alta resolução espacial das imagens ajuda a fornecer um maior nível de detalhamento, colaborando no processo de tomada de decisão (REMONDINO et al., 2011).

A fotogrametria utilizada a partir de ARP tem ganhado espaço no mercado atual e diversos estudos têm sido desenvolvidos nesse sentido, como de Candido et al. (2015) e Silgueiro et al. (2017), os quais afirmam que esta ferramenta possui um grande potencial, principalmente no que tange à resolução espacial, espectral; e precisão na geração de modelos digitais do terreno (MDT) ou modelos 3D (SIEBERT; TEIZER, 2014).

3.3.1 Produtos cartográficos provenientes de Aeronaves Remotamente Pilotadas (ARP)

Os produtos cartográficos tem por característica a representação de determinada parte da superfície terrestre. No caso dos produtos cartográficos provenientes de ARP, tem-se produtos de ordem planimétrica (Ortoimagem) e altimétrica (Modelo Digital de Elevação - MDE).

A teoria da ortorretificação é vista em alguns livros de fotogrametria, dentre os quais destaca-se: Albertz e Kreiling (1989) e Kraus (1993).

Segundo Andrade (1998), ortoimagem digital, depois de suas correções em relação ao relevo, é uma imagem passível de interpretação, sendo que quaisquer informações extraídas são inerentes as de um mapa. Almeida (1986) afirma que a ortoimagem mostra imagens em verdadeiras posições ortográficas, sendo geometricamente equivalente ao mapa de linha, podendo, sobre as ortoimagem, medir distâncias e ângulos horizontais e áreas. Tais características se apresentam como vantagem na delimitação espacial de elementos.

Além das características espaciais que uma ortoimagem pode oferecer, podem ser destacadas as características espectrais deste produto, dependendo da câmera utilizada (RGB – *Red, Green e Blue* ou NIR – *NearInfraRed*).

D'oliveira-oltmanns, Marzloff e Blaschke (2015) afirmam em seus estudos que o sensoriamento remoto a partir de produtos cartográficos oriundos de ARP, são estudos recentes que permitem mapear locais de estudo que variam em suas extensões de várias centenas de metros quadrados até centenas de quilômetros quadrados.

3.4 Segmentação de imagens

A resolução espacial das imagens derivadas de ARP torna possível a divisão de padrões que compõem os objetos pertencentes a esta imagem, a fim de melhorar a identificação de objetos específicos. Para Pratt (2007), a segmentação é definida como a divisão ou separação da imagem em regiões de atributos similares ou de mesmas características espectrais.

Desclée, Bogaert e Defourny (2006) retratam a divisão em grupos de pixels que são espectralmente similares e espacialmente adjacentes, formando regiões (ou objetos-imagem) por meio de um limiar de variabilidade entre os objetos. Blaschke et al. (2000), por sua vez, afirmam que a segmentação da imagem permite que atributos dos objetos sejam derivados, auxiliando no entendimento da imagem.

Segundo Baatz e Schäpe (2000), essa abordagem tende a aproximar as técnicas de processamento e extração de informações com raciocínio humano, de modo que a forma adotada para interpretar uma imagem ou apreciar uma paisagem, seja como um reconhecimento de padrões para o software.

O reconhecimento de padrões vem ao encontro das necessidades da comunidade da fotogrametria e sensoriamento remoto. Haja vista que as tecnologias e as ciências têm evoluído, logo as características da abordagem pixel a pixel se tornam menos eficientes no ramo da identificação de elementos. Os estudos de Blaschke et al. (2000) realizam uma

abordagem sobre o assunto, dizendo que o uso de segmentadores para fins de delineamento de objetos, trata-se da evolução do processamento digital de imagens e está associada ao reconhecimento de padrões em múltiplas escalas.

Antunes et al. (2003) afirmam que a análise baseada em objetos tem sido sugerida na literatura como uma das mais indicadas, para a classificação de imagens. Na identificação das classes não é considerada apenas a resposta espectral dos alvos, mas também as suas variantes geométricas, topológicas e de textura.

Chubey et al. (2006) em seus estudos sobre segmentação, coloca como grande e principal vantagem da segmentação de imagens, a grande quantidade de informações que pode ser derivada, como média, desvio padrão e outros descritores espectrais, espaciais, de textura, da forma, do tamanho e do contexto dos objetos.

Segundo Blascke et al. (2014), segmentação de imagens, de uma perspectiva algorítmica, é geralmente dividida em quatro categorias: (a) baseada em pontos, (b) baseada em borda, (c) baseada em região e (d) combinada. Os autores enfatizam que a segmentação sempre fornece os blocos de construção de análise de imagem baseada em objetos.

Segundo Baatz e Schape (2000), a análise desses dados texturizados só pode ser bem-sucedida se estes são segmentados em áreas "homogêneas" significativas. Para Blascke e Strobl (2001) a textura representa um elemento importante dentro da análise de objetos. O autor ainda afirma que a forte motivação para desenvolver técnicas para a extração de imagem objetos decorre do fato de que a maioria dos dados de imagem exibe textura característica que é negligenciada em comuns classificações.

3.4.1 Segmentação multirresolução e por diferença espectral (*Spectral Difference*)

Nesse contexto, a segmentação multirresolução vem sendo aplicada por consistir em um conceito humano de generalização intuitiva de áreas homogêneas, aplicado a um ambiente computacional (BLASCKE; STROBL, 2001).

Baatz e Schape (2000) afirmam que na segmentação multirresolução os objetos de interesse geralmente aparecem em diferentes escalas em uma imagem, simultaneamente; a extração de objetos de imagem significativos precisa levar em consideração a escala do problema a ser resolvido.

O algoritmo de segmentação multiresolution (utilizado no software eCognition®), aplica a abordagem de crescimento de regiões, onde o critério de similaridade é construído a partir do conceito de heterogeneidade interna das regiões. A heterogeneidade resulta da

diferença entre o atributo de uma região e a soma dos valores deste mesmo atributo para as duas sub-regiões que serão agrupadas caso o critério seja satisfeito. Assim, são calculados os coeficientes de heterogeneidade para os atributos de cor e forma. A soma ponderada destes dois coeficientes forma o critério de similaridade f expresso pela Equação 1, onde w_{cor} é o peso do atributo cor, h_{cor} é o coeficiente de heterogeneidade do atributo cor e h_{forma} é o coeficiente de heterogeneidade do atributo forma (Baatz et al., 2004; Baatz et al., 2000; Espindola e Câmara.,2007).

$$f = w_{cor} \cdot h_{cor} + (1 - w_{cor}) \cdot h_{forma}$$

Equação 01

Navulur (2007) diz que o algoritmo cria segmentos na imagem com base em cinco critérios referentes à: escala, cor, forma, suavidade e compacidade. O autor ainda descreve que a escala determina a heterogeneidade dos objetos junto dos critérios já descritos.

Tedesco (2015) descreve sobre esses elementos em seu estudo, afirmando que os parâmetros de escala (PE) e de heterogeneidade (PH) devem ser definidos pelo usuário. Sendo o PE um termo voltado para uma unidade mínima de mapeamento, o qual é responsável pelo tamanho de algum objeto-imagem correspondente a um determinado fator de escala. O autor ainda destaca que a determinação é empírica e deve se basear em experimentos.

Para Blaschke et al. (2000), o procedimento da segmentação multirresolução é similar ao de crescimento de regiões, sendo que cada escala gera um nível de agrupamentos de objetos, não existindo escala ideal.

A segmentação por diferença espectral é um algoritmo de segmentação, de mesclagem em que objetos vizinhos com uma média espectral abaixo do limite especificado (diferença espectral máxima) serão mesclados para produzir os objetos finais (DEFINIENS, 2007). Anjos (2016) descreve que este algoritmo é projetado para refinar os resultados da segmentação.

Lacerda et al. (2018) realizou um experimento em imagem derivada de ARP, segmentada a diferentes níveis de escala, forma e compacidade. O autor apresentou uma gama de resultados referentes ao efeito da variação de escala na qualidade de integração (junção) de objetos.

3.5 Mineração de dados (*Data mining*)

A partir dos mais diversos produtos cartográficos, torna-se possível a determinação de padrões de interesse, mediante alguns atributos contidos em tais produtos. Essa determinação é denominada mineração de dados (*Data mining*) e normalmente visa uma maior eficácia nos métodos de classificação orientada a objeto.

Para Souza e Kux (2014) a mineração de dados é uma aplicação de algoritmos computacionais sobre uma base de dados com o intuito de abstrair conhecimentos novos e úteis. Witten et al. (2011) definem *Data mining* como o processo de descoberta de padrões de dados, sendo realizada de forma automática ou semiautomática e os padrões devem ser significativos, na medida em que levam a algum avanço no ganho de informações através da análise dos dados disponíveis.

Tan et al. (2009) fazem do *Data mining* parte integrante da descoberta de conhecimento em bancos de dados, pois por meio do mesmo é possível realizar o processo geral de transformar dados brutos em informações, através de etapas de transformação, pré-processamento e pós-processamento dos resultados de mineração desses dados.

Goldschmidt e Passos (2005) afirmam que existem diferentes métodos de mineração de dados e destacam: redes neurais, algoritmos genéticos, instâncias, métodos estatísticos, métodos específicos, métodos baseados em indução de árvores de decisão e métodos baseados em lógica nebulosa.

Apanhando as definições anteriores, infere-se que pela mineração de dados é possível alcançar melhores resultados em quaisquer ciências que trabalhem com um grande volume de dados e que tenham por objetivo uma “mineração” ou escolha destes, sendo estas de uma maneira lógica e segura computacionalmente.

3.5.1 Árvores de decisão

Tan et al. (2009) afirmam em seus estudos que dentre os algoritmos mais utilizados na mineração de dados, encontra-se a árvore de decisão, que se trata de um classificador expresso como uma partição ou divisão recursiva do espaço de amostras/instâncias/exemplos (MAIMON; ROKACH, 2010).

As árvores de decisão são compostas de uma estrutura hierárquica, consistindo em nós e arestas direcionadas (Figura 4), sendo algumas das árvores mais precisas que outras, apresentando uma dificuldade em encontrar árvores ótimas. Apesar disso, tem-se desenvolvido algoritmos eficientes para induzir uma árvore de decisão razoavelmente precisa, em um determinado tempo computacional (TAN et al., 2009).

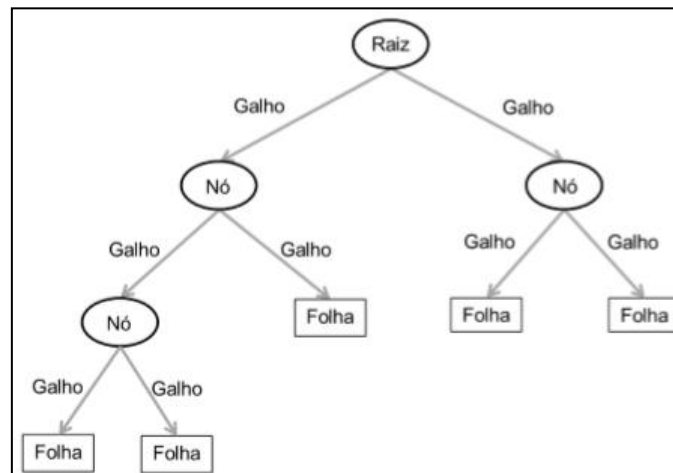


Figura 4. Representação gráfica de uma árvore de decisão.
Fonte: Tedesco (2015)

Para criar um modelo de classificação de árvore de decisão deve-se fornecer um conjunto de treinamento cujos nomes são conhecidos; a partir deste grupo de treinamento, um modelo de classificação é posteriormente aplicado ao conjunto de testes que consistem em registros de *tags* de classe desconhecidos (TAN et al., 2009).

Os algoritmos de indução de árvores de decisão correspondem a um método de aprendizado supervisionado, possibilitando a extração de dados a partir de amostras de treinamento. As amostras para classificação supervisionada são representadas por um vetor de valores de características, ou atributos, e o rótulo da classe associada (TEDESCO, 2015).

O algoritmo utilizado nesse estudo é o C 4.5, descrito por Quinlan (1993), este, tem como objetivo gerar um modelo classificador na forma de uma árvore de decisão, de modo a apresentar dois estados durante o processo, os quais são: folha que indica um ponto no final da classificação, sendo atribuída a uma classe e nó de decisão, onde baseando-se no atributo em análise, poderá conter uma ramificação seguida de uma folha ou uma sub-árvore para cada possível valor encontrado na base. Este algoritmo atua também como um seletor se atributos (seção 3.2.1.).

3.5.2 Extração de atributos

Atributos são variáveis que apresentam características de um determinado segmento. Tais variáveis podem apresentar diferentes aspectos, destacam-se: aspecto espectral, textura, brilho, média entre as bandas utilizadas, ou ainda do aspecto espacial, como orientação, área, ângulo, entre outros. Todos estes atributos estão vinculados a uma equação matemática que os descreve como é visto em (manual do ecognition). A grande importância desses atributos é

que a partir de uma imagem pode-se obter novos dados, referentes às características dessa imagem. Os atributos estão vinculados a cada segmento em uma imagem, sendo que este segmento pode ter inúmeros atributos. Os atributos funcionam como uma expressão de determinado segmento, fazendo com que seja possível analisar as características de um segmento a partir destes atributos.

A extração de atributos consiste na determinação de um conjunto de atributos que posteriormente podem ser levados a uma seleção, a partir de um determinado critério.

Segundo Pratt (1991), ao extrair as características mais importantes (atributos) de uma imagem, as diferenças e semelhanças entre os objetos devem ser enfatizadas. O autor afirma ainda, que alguns recursos são definidos por uma aparência visual na imagem. Essas funções incluem: o brilho de uma região específica, a textura de uma região, a amplitude do histograma e muito mais.

Para Duda et al. (2001), o principal objetivo da extração de atributos é a caracterização de objetos que devem ser reconhecidos por medidas na imagem.

3.5.3 Seleção de atributos

A seleção de atributos visa selecionar as melhores variáveis do conjunto de dados de entrada que serão utilizados na classificação. Nesse sentido, as imagens de entrada são transformadas ou sujeitas a operações aritméticas, a fim de gerar novos atributos e, assim, poder separar as classes de interesse com mais eficiência (ANJOS, 2016).

A seleção de atributos é a busca por um menor subconjunto com melhor precisão no processo de classificação é considerado um desafio por Oliveira, Dutra e Rennó (2005). Os autores justificam esta afirmação descrevendo que a seleção de atributos se baseia em distâncias estatísticas entre pares de classes, como também existem várias maneiras de medir a distância entre conjuntos de diferentes classes no espaço de atributo.

Entre métodos descritos na literatura para realização da seleção de atributos encontra-se a metodologia descrita por Theodoridis e Koutroumbas (1999), que adota a distância euclidiana, distância de Mahalanobis e distância de Bhattacharyya (medida da divergência entre duas populações estatísticas, definidas por suas distribuições de probabilidade) e a metodologia de Bhattacharyya (1943), definida como uma medida da semelhança entre duas distribuições estatísticas.

Neste estudo destacam-se três (3) algoritmos de seleção de atributos: *Classifier Attribute Eval*, *Principal Components*, *Info Gain Attribute Eval*.

O Classifier Attribute Eval avalia o valor de um atributo usando um classificador especificado pelo usuário, (definição trazida pelo software – WEKA 3.8). Este algoritmo define um Ranking com alguns com uma ordem do menos importante para o mais importante.

Segundo Souza (2017) a Análise de Componentes Principais (PCA) ou *PrincipalComponents* é uma técnica estatística que visa estudar diversas aplicações cuja dimensionalidade é alta, tendo como principal ideia, reduzir a dimensionalidade dos dados do conjunto, transformando subsequentemente em um novo conjunto de variáveis denominado de componentes principais, preservando ao máximo as informações originais. O autor ainda descreve que, o método transforma ortogonalmente um conjunto de variáveis correlacionadas para um conjunto de valores de variáveis linearmente não correlacionadas (componentes principais). Dunteman (1999), afirma que o PCA elimina informações redundantes e destaca alguns recursos ocultos, provenientes das informações contidas nas bases, visualizando as principais relações existentes entre as observações vistas.

Segundo Parmezan (2012) o método Information Gain Attribute Ranking (*Info Gain Attribute Eval*) visa selecionar os atributos por meio da avaliação individual (Das, 2001). O autor ainda descreve que a ideia básica desse método consiste em computar o ganho de informação (Han et al., 2011), baseado na medida de entropia (Mitra et al., 2002), para avaliar a relevância de um atributo com relação à classe.

3.6 Classificação de imagens

A classificação de imagens consiste no estabelecimento de um processo de decisão no qual um grupo de pixels é definido como pertencente a uma determinada classe. Nesse sentido, os sistemas computacionais auxiliam o usuário na interpretação das imagens orbitais (VENTURIERI; SANTOS, 1998).

Existem diferentes métodos e tipos de classificação. Os métodos utilizados na classificação são: supervisionado e não supervisionado. No método supervisionado, o modelo de conhecimento é abstraído a partir de um conjunto de treinamento e avaliado a partir do conjunto de teste. No método não supervisionado, não existe a informação de saída desejada, e os algoritmos partem dos dados procurando estabelecer relações entre si (GOLDSCHMIDT; PASSOS, 2005).

Quanto ao tipo de classificação se fala em classificação por pixel e classificação por região. Segundo () classificadores " pixel a pixel"¹, estes utilizam apenas a informação espectral de cada pixel para achar regiões homogêneas. Estes classificadores podem ser separados em métodos estatísticos (utilizam regras da teoria de probabilidade) e determinísticos (não utilizam probabilidade). O autor descreve que a Classificação por regiões, utilizam, além de informação espectral de cada "pixel", a informação espacial que envolve a relação com seus vizinhos. Procuram simular o comportamento de um fotointérprete, reconhecendo áreas homogêneas de imagens, baseados nas propriedades espectrais e espaciais de imagens. A informação de borda é utilizada inicialmente para separar regiões e as propriedades espaciais e espectrais irão unir áreas com mesma textura.

Pode se considerar que há uma constante melhora, no começo da era computacional, o desenvolvimento das classificações era em função da abordagem. Com o passar dos anos, tem-se a utilização dos sensores e câmeras garantindo, também pela resolução espacial, que os métodos computacionais levem à classificação a partir de padrões ou orientada com visto em Blaschke e Strobl (2001). O autores afirmam que existem algumas limitações na classificação pixel a pixel, sobretudo no que tange às imagens de alta resolução, já quando há a definição de padrões em uma imagem, a identificação de objetos específicos passa a ser mais bem definida.

3.6.1 Classificação Orientada a Objeto (GEOBIA)

A abordagem que trabalha com a classificação de objetos por meio de padrões podem ser definidas como GEOBIA (*Geographic Object Based Image Analysis*) ou Classificação Orientada a Objeto (COO), conceituada como ferramenta científica de base tecnológica, que tem a finalidade funcional de extrair, determinar e criar informações a partir da interação entre algoritmos e espaço imagem; enfatizando as características: objeto, forma, textura, contexto e padrão, integração semântica e conhecimento do usuário (HAY; CASTILLA, 2008). (Corrigir os padrões)

É visto nos estudos de Blaschke e Strobl (2001) e Hay e Castilla (2008) que em GEOBIA os segmentos são regiões geradas por um ou mais critérios de homogeneidade em uma ou mais dimensões (de um espaço de característica), respectivamente.

Quando analisado o uso de GEOBIA em imagens de alta resolução na delimitação de voçorocas é possível destacar alguns estudos que adotaram esta técnica, como de Bertalan e

¹Uma classificação pixel a pixel é aquela que utiliza este elemento como informação para a definição dos elementos que compõem a imagem.

TúrieSzabó (2016) que desenvolveram um estudo que permitiu classificar a ortoimagem e separar o solo exposto, da vegetação, permitindo a detecção de processos erosivos em Kázár, Hungria.

Doleire-oltmanns et al. (2012) apresentaram uma aplicação de sensoriamento remoto usando uma ARP, visando reduzir a lacuna de dados entre escala de campo e satélite para monitoramento da erosão do solo em Marrocos e, os produtos obtidos no estudo permitiram quantificar os processos erosivos.

Também é interessante mencionar o estudo de Shruthi et al. (2015) que determinaram um conjunto de regras e parâmetros de segmentação, desenvolvido para extração do elemento (objeto) voçoroca. Também, Tedesco (2015) realizou uma pesquisa utilizando GEOBIA e obteve resultados satisfatórios no que tange à classificação semiautomática do elemento voçoroca.

Diante desse contexto, é possível considerar que o uso da GEOBIA associada à obtenção de imagens de altas resoluções são ferramentas capazes de auxiliar no processo de monitoramento das voçorocas. Logo, o desenvolvimento de trabalhos que apresentem técnicas acessíveis e de fácil manuseio se apresenta como uma alternativa otimista no monitoramento e futura recuperação de áreas degradadas por voçorocas.

3.7 Padrão de exatidão cartográfico e padrão de exatidão cartográfico digital (PEC-PCD)

A evolução tecnológica junto da disseminação do conhecimento e popularização de equipamentos que utilizam dados e informações geoespaciais, fizeram com que houvesse uma significativa demanda por novos padrões de qualidade para os produtos cartográficos (MARTIN, 2019). O autor ainda afirma que para atender a estas necessidades, as Especificações Técnicas dos Produtos dos Conjuntos de Dados Geoespaciais (ET-PCDG) definiram os elementos da qualidade para cada tipo de produto cartográfico.

O indicador estatístico de qualidade posicional denominado PEC (Padrão de Exatidão Cartográfico) foi instituído pelo Decreto nº 89.817, de 20 de Junho de 1984, que estabelece critérios para classificação de cartas quanto a sua exatidão e a distribuição de erros ao longo das mesmas (BRASIL, 1984).

Segundo Toledo et al. (2018), com o avanço dos métodos de produção cartográfica houve a necessidade de uma revisão dos padrões estabelecidos inicialmente no Decreto nº 89.817/1984. O autor ainda afirma que, concomitantemente, a ET-ADGV (Especificação

Técnica para Aquisição de Dados Geoespaciais Vetoriais) definiu um novo Padrão de Exatidão Cartográfica com o objetivo de regular e atender a aquisição dos Produtos Cartográficos Digitais (PEC-PCD). Ainda, nas palavras do autor, o PEC-PCD, veio para atualizar o cálculo previsto na legislação citada anteriormente.

Para que um produto digital possa ser aceito como produto de Referência do SCN, e consequentemente para a INDE, a exemplo do previsto para o PEC (produtos impressos em papel), noventa por cento (90% ou $1,6449*EP$) dos erros dos pontos coletados no produto cartográfico, quando comparados com as suas coordenadas levantadas em campo por método de alta precisão, devem apresentar os valores iguais ou inferiores aos previstos ao PEC-PCD, devendo ainda apresentar os valores de EP também iguais, ou inferiores, aos previstos nas tabelas deste tópico. Para que sejam enquadrados nas classes do PEC-PCD, as discrepâncias entre as coordenadas dos pontos homólogos devem resultar em valores iguais ou inferiores de erro máximo (EM) e de erro padrão (EP) previstos para cada produto (TOLEDO et al., 2018).

Segundo o § 4º do item 2. do Art. 8º do Decreto nº 89.817/1984, os termos Desvio Padrão (DP), Erro Padrão (EP) e Erro Quadrático Médio (EQM) devem ser considerados como sinônimos. Visando expor de forma clara, precisa e concisa os conceitos relacionados com a qualidade posicional desejada para os Produtos Cartográficos Digitais (PCD), as novas especificações técnicas de tais produtos utilizam os termos precisão e exatidão (BRASIL, 1984).

Para a avaliação da ortoimagem e do modelo digital de terreno em relação ao PCD, utilizou-se o Erro Médio Quadrático (EMQ - RMS (*Root Mean Square*)) proposto por Mikhail e Ackermann (1976), o qual apresenta uma medida de acurácia apresentada pela Equação 1.

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$

(Equação 1)

Onde:

n = número de amostras;

X_i = valor fornecido pelo classificador para a i-ésima amostra;

\bar{X} = média dos valores de todas as amostras.

Nas Tabelas 1 e 2 são apresentados os valores da PEC-PCD, consultadas para o enquadramento dos produtos cartográficos gerados.

Tabela 1. Padrão de exatidão cartográfica da planimetria dos produtos cartográficos digitais.

PEC ⁽¹⁾	PEC-PCD	1:1.000		1:2.000		1:5.000		1:10.000		1:25.000		1: 50.00		1:100.000		1:250.000	
		PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)
-	A ⁽²⁾	0,28	0,17	0,56	0,34	1,40	0,85	2,80	1,70	7,00	4,25	14,00	8,51	28,00	17,02	70,00	42,55
A	B ⁽¹⁾	0,50	0,30	1,00	0,60	2,50	1,50	5,00	3,00	12,50	7,50	25,00	15,00	50,00	30,00	125,00	75,00
B	C ⁽¹⁾	0,80	0,50	1,60	1,00	4,00	2,50	8,00	5,00	20,00	12,50	40,00	25,00	80,00	50,00	200,00	125,00
C	D ⁽¹⁾	1,00	0,60	2,00	1,20	5,00	3,00	10,00	6,00	25,00	15,00	50,00	30,00	100,00	60,00	250,00	150,00

Fonte: ET-ADGV (2020)

Tabela 2. Padrão de exatidão cartográfica altimétrica dos pontos cotados e do MDT, MDE e MDS para a produção de produtos cartográficos digitais.

PEC-PCD	1:1.000 (Eqd= 1m)		1:2.000 (Eqd= 1m)		1:5.000 (Eqd= 2m)		1:10.000 (Eqd= 5m)		1:25.000 (Eqd=10m)		50.00 (Eqd= 20m)		1:100.000 (Eqd= 50m)		1:250.000 (Eqd= 100m)	
	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)	PEC (m)	EP (m)
A ⁽²⁾	0,27	0,17	0,27	0,17	0,54	0,34	1,35	0,84	2,70	1,67	5,50	3,33	13,70	8,33	27,00	16,67
B ⁽¹⁾	0,50	0,33	0,50	0,33	1,00	0,66	2,50	1,67	5,00	3,33	10,00	6,66	25,00	16,66	50,00	33,33
C ⁽¹⁾	0,60	0,40	0,60	0,40	1,20	0,80	3,00	2,00	6,00	4,00	12,00	8,00	30,00	20,00	60,00	40,00
D ⁽¹⁾	0,75	0,50	0,75	0,50	1,50	1,00	3,75	2,50	7,50	5,00	15,00	10,00	37,50	25,00	75,00	50,00

Fonte: ET-ADGV (2020)

Nos estudos de Sampaio e Brandalize (2018) são citadas algumas normas nacionais e internacionais, ambas tratando sobre um mínimo de pontos para avaliação da acurácia posicional: trata-se de 20 pontos de controle em áreas menores do que 500 km². O autor ainda define que, estes pontos devem ser bem definidos no terreno, devendo ser de fácil localização, fácil capacidade de retorno e verificação de sua posição a partir de equipamentos precisos. Sendo que os pontos de controle utilizados na avaliação da acurácia posicional devem possuir precisão no mínimo três vezes superior ao do produto que se pretende avaliar.

4 METODOLOGIA

4.1 Caracterização da área de estudo

O estudo foi realizado em duas áreas situadas no município de Itajubá- MG, sendo a Área 1 localizada em 22°25'23.03" Sul e 45°29'52.81" Oeste (Figura 5) e a Área 2 localizada em 22°25'23.03" Sul e 45°29'52.81" Oeste (Figura 6).

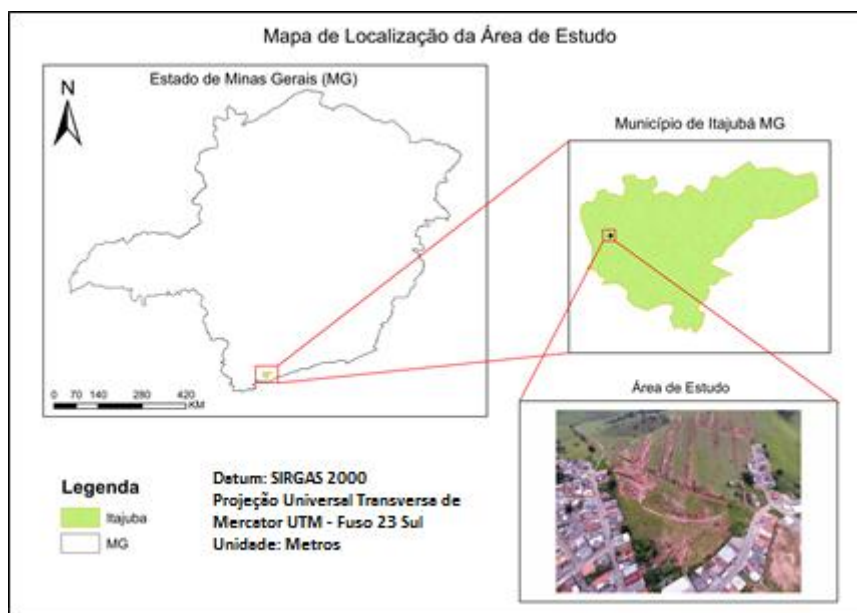


Figura 5. Mapa de localização da Área de estudo 1.
Fonte: Autor (2020).

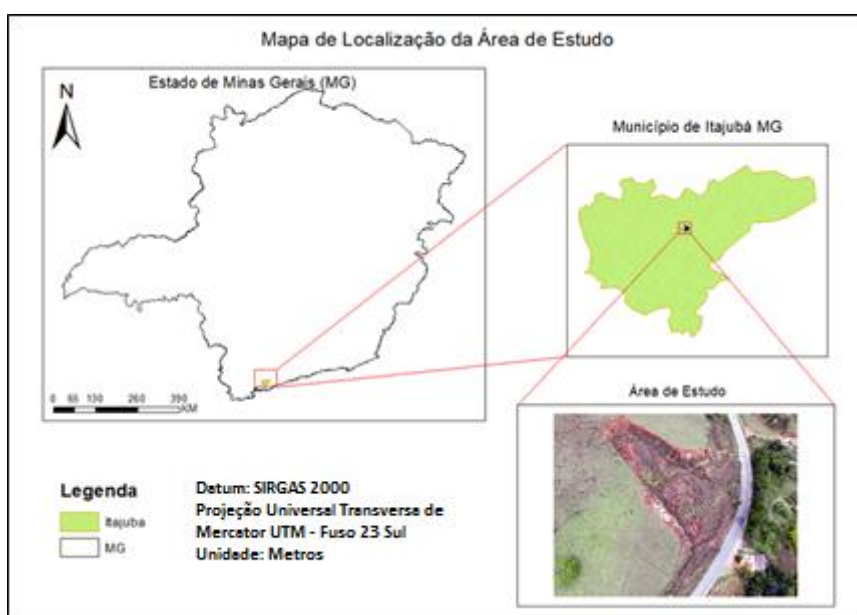


Figura 6. Mapa de localização da área de estudo 2.
Fonte: Autor (2020).

O município de Itajubá- MG possui uma área total de 294,84 km² e está situado na sub-bacia do Rio Sapucaí a uma altitude média de 900 metros e apresenta nível médio pluviométrico entre 1400 a 1800 mm, com clima Cwa (clima temperado úmido com inverno seco e verão quente), segundo a classificação de Köppen e Geiger, com temperatura média anual de 20,5°C.

A voçoroca presente na Área de estudo 1 (Figura 7a) se encontra em uma área de solo exposto, em alta para baixa vertente, com atividade de uso para loteamento; próximo à área urbana, com aproximadamente 180.000 m² (18,00 hectares).

A voçoroca presente na Área de estudo 2 (Figura 7b), tem a área de vegetação predominante de pastagem, com atividade de pecuária intensa, alta para baixa vertente em área rural, com aproximadamente 20.000 m² (2,00 hectares).



Figura 7. a) Voçoroca na área de estudo 01 e b) Voçoroca na área de estudo 02.
Fonte: Autor (2020).

A área do município compreende uma estrutura de solo predominante em Gleissolo Háplico e Argissolo Vermelho amarelo, assim como pode ser observado nas Figuras 8 e 9.

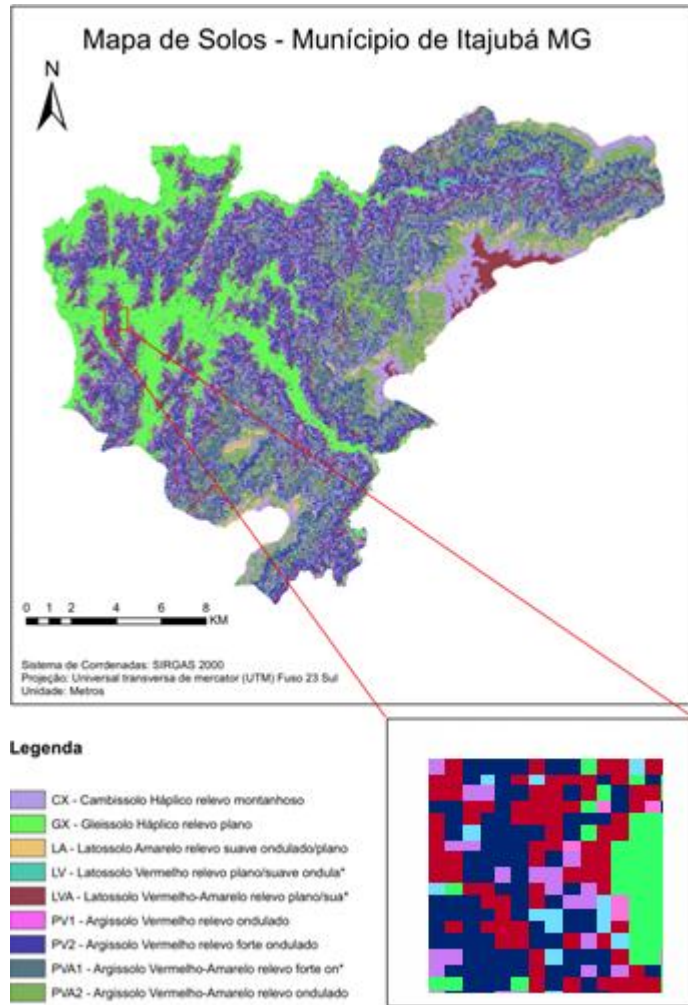


Figura 8. Tipo de solo da Área de estudo 1.

Fonte: (IBGE, 2019).

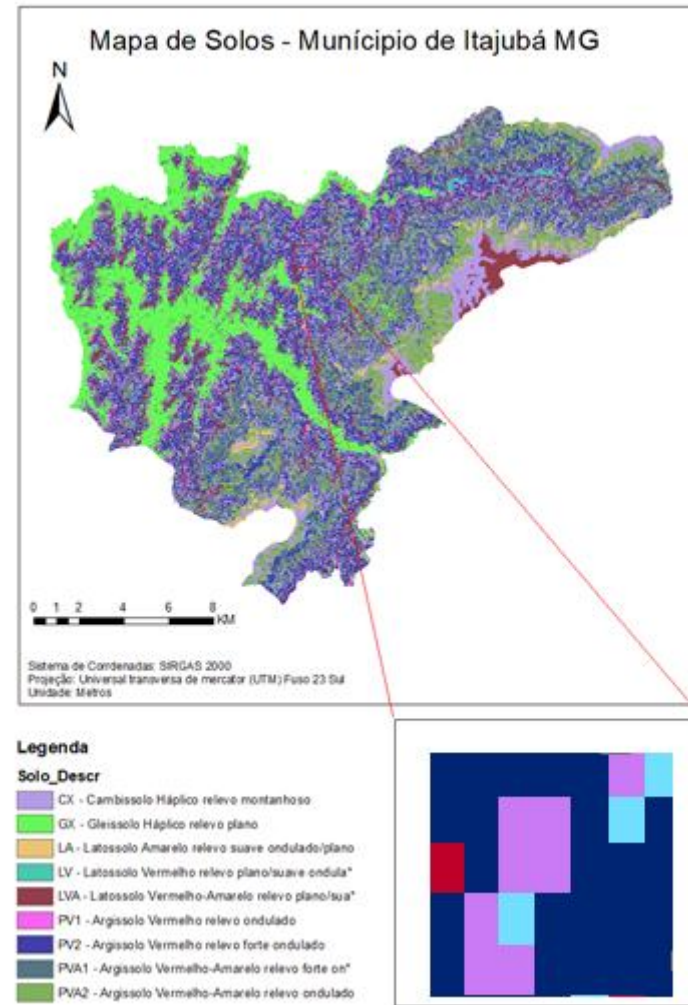


Figura 9. Tipo de solo da Área de estudo 2.

Fonte: (IBGE, 2019).

4.2 MÉTODO

A Figura 10 apresenta um esquema com as etapas da metodologia.

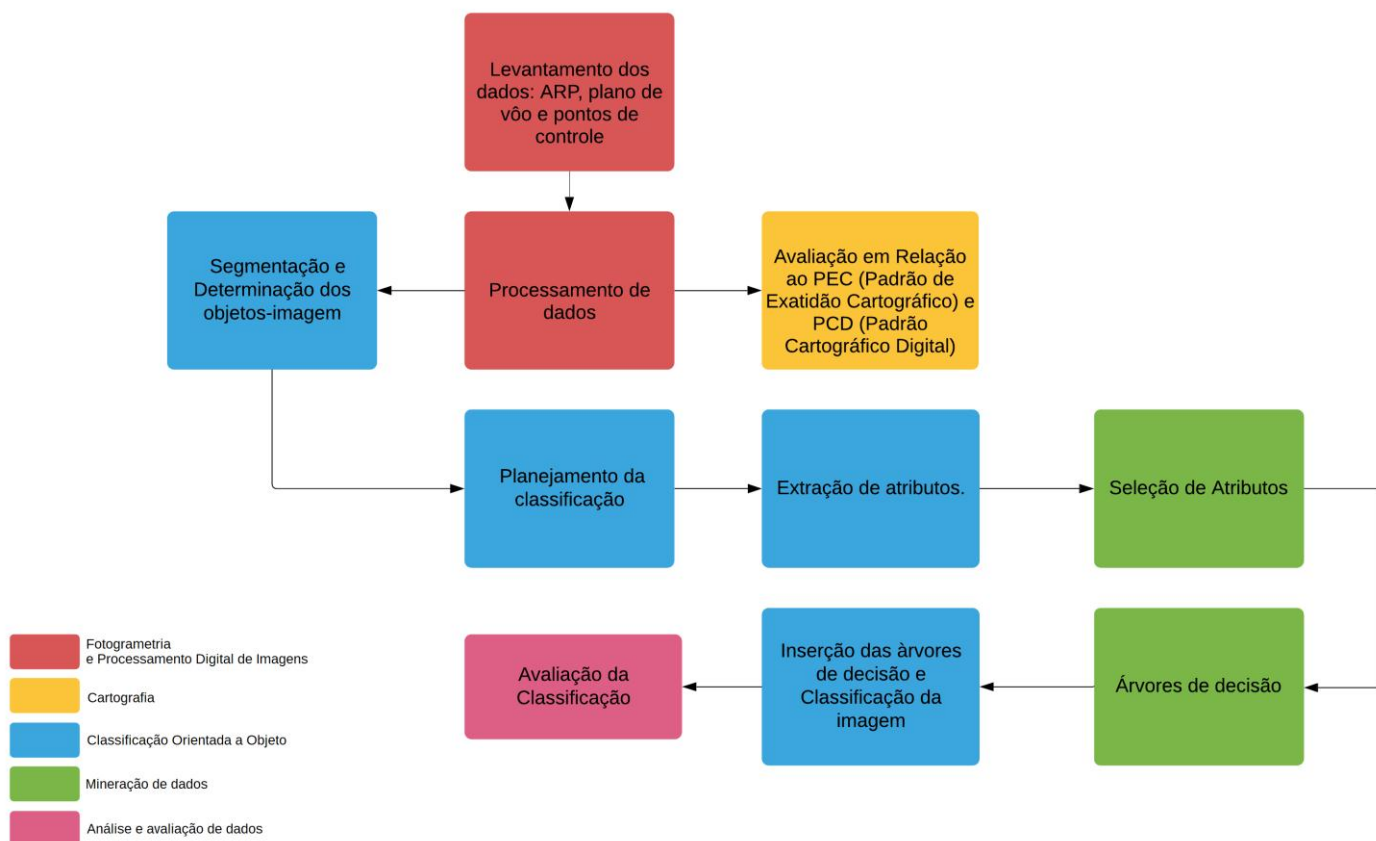


Figura 10. Esquema – Método.
Fonte: (O Autor)

O planejamento de vôo e a definição dos pontos de controle foram os primeiros procedimentos, o qual teve como base o levantamento fotogramétrico com a ARP, logo em seguida executou-se o voo (levantamento dos dados). A etapa seguinte foi o processamento dos dados levantados com a ARP. A partir deste processamento, obteve-se os produtos cartográficos (Ortoimagem e MDE - Modelo Digital de Elevação) que foram avaliados na etapa seguinte. A avaliação por sua vez foi realizada com o auxílio computacional (programa GeoPEC), com o objetivo de classificar o produto cartográfico gerado em relação ao PCD.

Após o levantamento e processamento de dados, a etapa seguinte consistiu no procedimento da classificação orientada a objeto. Na sequência, foi realizada a segmentação de imagens, onde foram definidos os parâmetros de segmentação ótimos para a identificação do elemento de estudo, que aparece na imagem.

Após a etapa de segmentação, definiu-se o planejamento da classificação. Esta etapa consistiu na definição das classes que compuseram a classificação de cada área, bem como as suas características, de acordo com o conhecimento especialista do autor sobre a área de estudo e os elementos que a compõem.

A partir da etapa de planejamento tornou-se possível delimitar dados para a classificação por mineração de dados e árvore de decisão. Esse procedimento consistiu no uso da mineração de dados para definir quais atributos são relevantes (Seleção de Atributos) para a classificação das imagens. A árvore de decisão, por sua vez, define um caminho para esta classificação e, neste caso, utilizou-se o algoritmo C 4.5.

A etapa da classificação e avaliação da classificação consistiu na análise dos resultados gerados pela árvore de decisão no software, de maneira estatística (Exatidão Global e índice Kappa) e Temática.

4.2.1 Levantamento dos dados: ARP, pontos de controle e plano de vôo

O levantamento dos dados foi realizado com a ARP *Phantom4*, regulamentada pelos órgãos responsáveis (Cadastro ANAC - PP-250819931), tendo a bordo uma câmera *Sony Exmor* de 12 megapixels (Figura 11).

A configuração da aeronave (Gimbal e GNSS) bem como os parâmetros FOV (*Field of View* – Campo de Visada) e luminosidade foram realizados no software *DJI Go 4*, em celular na plataforma *Android*.

Nesta etapa é importante ressaltar que as configurações foram estabelecidas empiricamente, porém, tendo um mesmo padrão para o levantamento das duas áreas de estudo. Na Tabela 3 são descritas as principais características do equipamento utilizado no estudo em comparação a outros equipamentos.



Figura 11. Equipamento ARP utilizado no estudo (*Phantom 4*).
Fonte: Autor (2020).

Tabela 3. Principais características da ARP utilizada no estudo (ARP Phantom 4) em comparação com outras aeronaves.

ARP	Largura do sensor (mm) s_w	Altura do sensor (mm) s_h	Distância focal equivalente a 35 mm F_{34} (mm)	Largura da imagem (pixel)	Altura da imagem (pixel)	Distância focal verdadeira (FR) (mm)
DJI Phantom 4	6,17	4,6	20	4.000	3.000	3,5665
DJI Mavic	6,17	4,6	28	4.000	3.000	4,9931
DJI Phantom 4 Pro	13,2	8,8	24	5.472	3.648	9,1561

Fonte: Adaptado de Embrapa (2009).

O plano de voo foi elaborado utilizando o *software open Source Drone Deploy*, via celular na plataforma *Android*. A princípio, analisaram-se as características da área levantada *in loco*, determinando a segurança da altura de voo e, em seguida, foi determinada a resolução espacial desejável a partir do GSD (*Ground Sample Distance*) correspondente ao tamanho do pixel no terreno.

O cálculo do GSD seguiu um produto simples que se relaciona com o tamanho do pixel na imagem e a escala da imagem, como descrito por Leachtenauer e Driggers (2001) e Driggers (2003). Deste modo, para uma distância focal predefinida da câmera digital, a altura de voo determina o tamanho do GSD. Na Figura 12 são ilustrados os aspectos considerados no cálculo do GSD.




Figura 12. Cálculo GSD.

Fonte: Adaptado de Silva Neto (2015).

Na sequência, foram definidos os padrões de velocidade de voo, recobrimento lateral e longitudinal. Todas estas configurações se encontram no software *DJI Go 4.0* e *Drone Deploy*. Os voos em campo foram comandados pelo programa *Drone Deploy* na sua forma de aplicativo para celular.

Na Tabela 4 são descritos os parâmetros adotados para a realização dos voos na Área de Estudo 1 e Área de Estudo 2.

Tabela 4. Parâmetros de voo estabelecidos para a Área de estudo 1 e 2.

Parâmetro	Área de estudo 1	Área de estudo 2
Velocidade de Vôo	15 metros/segundo	15 metros/segundo
Altura de Vôo	100 metros	100 metros
<i>Over Lap</i> (Recobrimento Longitudinal)	70%	70%
<i>Side Lap</i> (Recobrimento Lateral)	60%	60%
Abertura da Câmera	f/2	f/2

Fonte: Autor (2020).

Os voos foram realizados conforme as normas previstas para os levantamentos aéreos, entre os meses de dezembro de 2018 (Área de Estudo 1) e março de 2019 (Área de Estudo 2), próximo às 12 horas.

Os pontos de controle ou *Ground Control Points* (GCPs) definidos como as referências no espaço físico (espaço objeto) foram constituídos de elementos naturais (maioria) e artificiais. Especificamente, foram utilizadas placas de isopor de tamanho (0,5 metro por 1,0 metro), coloridas na cor azul na forma de mosaico, assim como ilustrado na Figura 13.



Figura 13. Elementos artificiais utilizados como pontos de controle.
Fonte: Autor (2020).

Foram estabelecidos cinco pontos de controle em ambas áreas de estudo, os quais foram distribuídos de maneira homogênea. Por meio de receptores GNSS (*Global Navigation Satellite System*), modelo CHC X900 L1/L2 (ondas portadoras de sinal), todos os pontos de controle tiveram suas respectivas coordenadas mensuradas. Para tal procedimento, foi adotada a técnica de levantamento relativo cinemático em tempo real ou técnica RTK (*Real Time Kinect*). Ainda sobre os pontos de controle, vale ressaltar que as coordenadas da base GNSS, foram processadas utilizando o método PPP (Posicionamento por Ponto Preciso) – IBGE.

Na Tabela 5 são apresentadas as coordenadas UTM (Universal Transversa de Mercator) dos pontos de controle adotados na Área de Estudo 1 e Área de Estudo 2.

Tabela 5. Coordenadas coletadas dos pontos de controle das áreas de estudo.

Pontos de controle	Área de estudo 1		Área de estudo2	
	(Este/Norte - metros)		(Este/Norte - metros)	
P1	448775,061	7520334,050	456651,623	7522829,906
P2	448646,255	7520345,895	456599,600	7522923,452
P3	448635,934	7520150,216	456621,380	7522976,555
P4	448716,650	7520115,999	456689,165	7522961,383
P5	448959,835	7520183,947	456779,413	7522992,186

Fonte: Autor (2020).

Vale ressaltar que os pontos de controle são de fundamental importância para o processamento das imagens, tendo a função de orientar e ajustar os blocos para a fototriangulação.

Sobre o espaço objeto são determinados pontos de verificação (checagem) ou *check*

points, os quais são pontos semelhantes aos pontos de controle em sua forma de determinação, mas com a função de verificar o produto final gerado. Os pontos de verificação podem ser naturais ou artificiais e, neste estudo, foi predominante o uso de pontos de verificação naturais (já inseridos naturalmente no espaço geográfico - ex: beira de calçada).

Com a determinação das coordenadas reais desses pontos foi possível posteriormente compará-las às coordenadas desses mesmos pontos geradas pelo produto cartográfico em questão. Esses pontos são os pontos utilizados na seção 4.2.3 – Avaliação dos produtos cartográficos em Relação ao PCD (Padrão Cartográfico Digital).

4.2.2 Processamento dos dados e Confeção dos produtos cartográficos

O processamento das imagens se deu pelas etapas de alinhamento das imagens, densificação dos pontos chaves (homólogos), inserção dos pontos de controle, construção de nuvens de pontos, construção do modelo em faces de triangulação e texturização de modelo.

Utilizou-se o *software Agisoft Photo Scan* versão 1.4.3 para a confecção dos produtos cartográficos principais: Ortoimagem Digital e MDE; no entanto, existe a possibilidade de classificar alguns objetos sobre a nuvem de pontos geradas com o programa. Este foi o processo utilizado para a confecção do Modelo Digital de Altura (MDA) e Modelo Digital de Terreno (MDT).

Sobre a construção dos produtos nestas etapas, foi inserida a orientação (coordenadas) dos pontos de controle coletados *in loco*, a fim de que se pudessem gerar produtos cartográficos com características do espaço métrico (real), para os quais foram determinadas as informações. Esses pontos garantem a confecção do produto que posteriormente será avaliado na seção 4.2.3.

4.2.3 Avaliação dos produtos cartográficos em relação ao PCD (Padrão Cartográfico Digital)

Os produtos cartográficos gerados são as bases de dados utilizadas no estudo. A partir destes produtos podem ser gerados outros derivados como: Modelo Digital de Terreno (MDT), Modelo Digital de Altura (MDA), Nuvem de Pontos, Mapa de Declividade e outros. O uso de tais produtos exige uma garantia de acuidade e precisão, a fim de que se possa minimizar os erros referentes à cartografia de cada um.

Para a aplicação do Padrão de Exatidão Cartográfica (PEC) e Padrão Cartográfico Digital (PCD) utilizou-se o Software GeoPEC versão 3.5.1. O software trabalha com três normas/padrões:

- (i) Acurácia posicional de produtos cartográficos utilizando o Decreto nº. 89.817/1984 aliada à ET-CQDG;
- (ii) Inspeção topográfica através da NBR 13.133 e;
- (iii) avaliação de ortoimagem de aerolevanteamento e bases cartográficas utilizadas no processo de Georreferenciamento de Imóveis Rurais segundo Norma de Execução n. 02 de 2018 do INCRA.

Além das normas citadas acima, o software conta com Análise de Tendência: Teste de Normalidade Shapiro Wilk, Teste T Student, Padrão de distribuição espacial: Vizinho mais próximo.

Foram inseridos, no software, os alvos de verificação (pontos de checagem/pontos de referência) e suas respectivas coordenadas geradas pelo produto cartográfico (pontos teste), a fim de obter a classificação em relação à PEC/PCD. Ao todo foram inseridos 21 pontos para verificação Planimétrica e Altimétrica. (Ortoimagem e MDE)

As etapas adotadas para a verificação de cada produto segundo a PEC-PCD são descritas a seguir:

Para a Ortoimagem e Modelo Digital de Elevação:

- Inserção das coordenadas dos pontos de checagem no software GeoPEC.
- Inserção das coordenadas dos pontos obtidos da imagem orientada.
- Escolha da Escala.
- Consulta ao padrão PEC-PCD e associação a Classe correspondente.

Vale ressaltar que ambas as imagens, depois de validadas, foram recortadas de modo a contemplar somente a área de estudo e reduzir o custo computacional das demais etapas de processamento e mineração de dados.

4.2.4 Segmentação e determinação dos objetos imagens

Para a Área de Estudo 1

Na Área de Estudo 1 foram utilizadas as 3 bandas (*Red, Green, Blue*) provenientes da câmera Sony EXMOR, acoplada na ARP. A área está situada em perímetro urbano, com vegetação rasteira e voçorocas em algumas ruas que foram abertas para instalação de loteamento. Na imagem obtida são observados telhados de diferentes tipos (fibrocimento e cerâmica).

Utilizou-se o algoritmo *Multiresolution* com um fator de escala fixo, pois a delimitação dos elementos (objetos) se mostrou suficiente para o nível de escala utilizado (FE= 10) com os valores de Forma= 0,5 e Compacidade= 0,5. Em seguida, utilizou-se a segmentação pelo algoritmo *Spectral Difference* com Limiar de diferença igual a 1. O algoritmo *Multiresolution* permitiu uma discriminação detalhada dos elementos pertencentes à imagem.

Na sequência, o algoritmo *Spectral Difference* uniu os segmentos mais parecidos dentro do limiar específico. A combinação destes dois algoritmos permitiu uma boa diferenciação dos elementos, garantindo segmentos homogêneos. Os pesos da segmentação ficaram sobre as bandas espectrais (R, G, B), não incluindo MDE, MDT e MDA. sendo utilizados na classificação e mineração de dados.

Para a Área de Estudo 2

Na Área de Estudo 2 também se utilizou das 3 bandas (*Red, Green, Blue*), provenientes da câmera Sony EXMOR, acoplada na ARP. As características da voçoroca que compõe a área de estudo 2 são diferentes da Área de Estudo 1. Na voçoroca da Área de Estudo 2 predomina um estado de degradação mais intenso, logo, é possível percebê-la com mais facilidade.

As características de cor e textura não se assemelham com uma voçoroca tradicional, há vegetação em estado de senescência em meio a voçoroca e, além disso, as bordas são bastantes características.

Na imagem, ainda pode ser observada uma grande área com predominante pastagem, com casas, árvores de grande porte, sendo de vegetação nativa, rodovia e animais. Utilizou-se um fator de escala fixo, pois a delimitação dos elementos (objetos) se mostrou




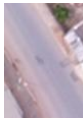



suficiente para o nível de escala utilizado (FE= 10) com os valores de Forma= 0,5 e Compacidade= 0,5. Já para o Algoritmo *Spectral Difference* o limiar foi de valor 1.

4.2.5 Planejamento da classificação

O planejamento da classificação se deu a partir de uma análise de conhecimento especialista de cada área de estudo. Tedesco (2015) descreve algumas etapas dentro deste processo, sendo três delas utilizadas aqui: seleção de atributos, rede semântica e chaves de interpretação.

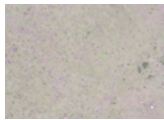





Nos Quadros 2 e 3 são apresentadas as características observadas em cada área de estudo de acordo com a imagem obtida.

Quadro 2. Chaves de interpretação - Área de Estudo 01.

Planejamento de Classificação - Área de Estudo 01			
Classe	Amostra	Cor	Forma, Textura e Variação da Altura
Vegetação Rasteira		Verde (variando tons claros e marrons)	Forma parcialmente regular, textura parcialmente lisa com traços de rugosidade, leve variação de altura.
Vegetação Arbórea		Verde (variando tons escuros, rugosidade e textura em destaque)	Forma irregular, textura rugosa, grande variação de altura.
Solo Exposto		Marrom (Claro) e Branco	Forma parcialmente regular, textura lisa, com pequenas variações de altura.
Vias/Asfalto		Cinza (variando levemente a coloração)	Forma parcialmente regular, textura lisa, com pequenas variações de altura.
Telhado em Cerâmica		Marrom (Variando tons claros e escuros)	Forma regular, textura parcialmente lisa, com grande variação de altura.
Telhado de Fibrocimento/ Cimento		Cinza (variando tons escuros)	Forma regular, textura parcialmente lisa, com grande variação de altura.
Voçoroca		Mistura de solos, vegetação e sombreamento	Formas irregulares; textura rugosa; com variação de altura significativa.

Fonte: Autor (2020).

Quadro 3. Chaves de interpretação - Área de Estudo 02.

Planejamento de Classificação - Área de Estudo 02			
Classe	Amostra	Cor	Forma, Textura e Variação da Altura
Vegetação Rasteira		Verde (variando tons claros)	Forma parcialmente regular, textura parcialmente lisa com traços de rugosidade, leve variação de altura.
Vegetação Arbórea		Verde (variando tons escuros)	Forma irregular, textura rugosa, grande variação de altura.
Solo Exposto		Marrom (Claro) e cinza	Forma parcialmente irregular, textura parcialmente rugosa, com pequenas variações de altura.
Rodovia/Asfalto		Cinza (variando levemente a coloração), faixa amarela.	Forma parcialmente regular, textura lisa, com pequenas variações de altura.
Vegetação Presenta na Voçoroca		Mistura de vegetações e solo.	Formas irregulares; textura rugosa; com baixa variação de altura.
Voçoroca		Mistura de solos, vegetação e sombreamento	Formas irregulares; textura rugosa; com variação de altura significativa.

Fonte: Autor (2020).

A partir deste levantamento, determinou-se alguns elementos chaves de interpretação como: cor, forma, textura e variação de altura dos objetos, definidas no planejamento apresentado nos Quadros 1 e 2.

Os atributos em si foram determinados para mineração de dados, tomando como base a metodologia de Tedesco (2015), Anjos (2016) e Bento (2017).

4.2.6 Extração de Atributos

O conjunto de atributos selecionados para o treinamento da árvore de decisão normalmente são determinados posteriormente à determinação dos parâmetros da segmentação. Para a extração de atributos são determinadas algumas amostras referentes aos seguimentos já pré-estabelecidos pela segmentação. Essas amostras são previamente classificadas e, em seguida, são exportadas, contendo os atributos pertinentes à escolha do usuário.

Neste estudo foram determinados os mesmos atributos para as duas áreas de estudo, já que o elemento Voçoroca (objeto de estudo) se encontra nas duas áreas.

O programa utilizado apresenta alguns atributos sobre cada parte segmentada (objeto-imagem) na imagem, sendo que esses atributos podem ser da ordem: espectral, geométrica, hierárquica, de textura, de posição e temáticas (relacionadas à classe que pertencem os objetos) (TRIMBLE, 2012).

A seleção primária dos atributos foi realizada mediante o conhecimento especialista para a área de estudo, apoiada nos estudos de Tedesco (2015) e Anjos (2016), resultando na extração de 64 atributos.

Os atributos extraídos para este estudo encontram-se descritos na tabela 6.

Tabela 6. Atributos submetidos à mineração de dados para as áreas 1 e 2.

N°	Atributos
1	Ratio R
2	Ratio MDT
3	Ratio MDE
4	Ratio MDA
5	Ratio G
6	Ratio B
7	Border length
8	Border Contrast R
9	Border Contrast MDT
10	Border Contrast MDE
11	Border Contrast MDA
12	Border Contrast G
13	Border Contrast B
14	Asymmetry
15	Min. Pixel value R
16	Min. Pixel value MDT
17	Min. Pixel value MDE
18	Min. Pixel value MDA
19	Min. Pixel value G
20	Min. Pixel value B
21	GLCM Contrast (quick 8/11) (all dir.)
22	Max. Diff.
23	Mean of outer border R
24	Mean of outer border MDT
25	Mean of outer border MDE
26	Mean of outer border MDA
27	Mean of outer border G
28	Mean of outer border B
29	GLCM Homogeneity (quick 8/11) (all. dir.)
30	GLCM Entropy (quick 8/11) (all. dir.)
31	Length/Width
32	Mean of inner border R
33	Mean of inner border MDT
34	Mean of inner border MDE
35	Mean of inner border MDA
36	Mean of inner border G
37	Mean of inner border B
38	Standart deviation R
39	Standart deviation MDT
40	Standart deviation MDE
41	Standart deviation MDA
42	Standart deviation G
43	Standart deviation B
44	Mean R
45	Mean MDT
46	Mean MDE


Continua.

Tabela 7. Atributos submetidos à mineração de dados para as áreas 1 e 2.

N°	Atributos	Continuação.
47	Mean MDA	
48	Mean G	
49	Mean B	
50	Max. Pixel value R	
51	Max. Pixel value MDT	
52	Max. Pixel value MDE	
53	Max. Pixel value MDA	
54	Max. Pixel value G	
55	Max. Pixel value B	
56	Class name (0 0)	
57	Circular Mean R (R1 Length 3 R2 Same (= R1) border)	
58	Circular Mean MDT (R1 Length 3 R2 Same (= R1) border)	
59	Circular Mean MDE (R1 Length 3 R2 Same (= R1) border)	
60	Circular Mean MDA (R1 Length 3 R2 Same (= R1) border)	
61	Circular Mean G (R1 Length 3 R2 Same (= R1) border)	
62	Circular Mean B (R1 Length 3 R2 Same (= R1) border)	
63	Compactness	
64	Brightness	


Fonte: Autor (2020).

As Figuras 14 e 15, apresentam as amostram coletadas nas Áreas de Estudo 1 e 2.



- Asfalto
- Solo Exposto
- Telhado Amianto
- Telhado Fibrocimento/Metalica
- Vegetacao Arborea
- Vegetacao Rasteira
- Voco-roca

Figura 14. Amostras coletadas - Área de Estudo 1.
Fonte: Autor (2020)



- Rodovia
- Solo Exposto
- Vegetação Arbórea
- Vegetação Rasteira
- Vegetacao presente na Voco-roca
- Voco-roca

Figura 15. Amostras coletadas - Área de Estudo 2.
Fonte: Autor (2020)

Após a determinação dos atributos, os dados foram tabulados e organizados para a entrada no programa WEKA versão 3.8 (*Waikato Environment for Knowledge Analysis*).

Segundo Hall *et al.* (2009), o *software* WEKA é um sistema de Mineração de Dados (*Data Mining*) e Aprendizado de Máquina (*Machine Learning*), com interface que apresenta algoritmos de regressão, classificação, agrupamento (*clustering*), regras de mineração, associação e seleção de atributos.

4.2.7 Seleção de atributos por mineração de dados.

A seleção de atributos consiste na determinação (seleção) de um conjunto de atributos, derivados de um conjunto de amostras. Tal seleção é feita a partir de um algoritmo. Normalmente, os mais utilizados são os do tipo *Ranker* (Ordenamento) ou *BestFirt* (Primeiro melhor). Para o estudo utilizou-se três algoritmos (Tabela 8), a fim de analisar se haveria uma diferença significativa na qualidade da geração das árvores de decisão.

Tabela 8. Algoritmos utilizados para a Seleção de Atributos - WEKA 3.8.

Algoritmos utilizados para a Seleção de Atributos - WEKA 3.8	<i>ClassifierAttributeEval</i>
	<i>PrincipalComponents</i>
	<i>InfoGainAttributeEval</i>

Foram geradas para cada resultado de seleção de atributos uma árvore de decisão a fim de que se pudesse verificar a qualidade de cada uma delas em relação à árvore gerada sem a seleção de atributos. O algoritmo c 4.5 foi o classificador utilizado para gerar a árvore de decisão. Este algoritmo é utilizado em alguns trabalhos que envolvem o uso da GEOBIA, mineração de dados aplicados a produtos cartográficos e imagens multiespectrais como em Tedesco (2015) e Anjos (2016).

4.2.8 Árvore de decisão

As árvores de decisão foram geradas utilizando o Software WEKA 3.8 e o algoritmo C 4.5 (C4.5, nome também utilizado). Quinlan (1993), o desenvolvedor do algoritmo, define em seus estudos que a árvore de decisão é usada para classificar um caso a partir do seu nó-raiz e segue movendo-se por ela até que uma folha seja detectada (uma folha indica uma classe). O autor ainda afirma que em cada nó de decisão não-folha, tem-se um teste para ser realizado relativo a um único atributo, com uma ramificação ou sub-árvore, podendo ser gerados novos resultados ou ramificações.

Foram geradas 4 árvores de decisão (mostradas no Apêndice 01) para cada área de estudo, utilizando o algoritmo C 4.5. As árvores foram geradas sob as seguintes condições:

- Árvore gerada a partir do conjunto total de atributos.
- Árvore gerada a partir da seleção de alguns atributos com o algoritmo *ClassifierAttributeEval*.
- Árvore gerada a partir da seleção de alguns atributos com o algoritmo *PrincipalComponents*.
- Árvore gerada a partir da seleção de alguns atributos com o algoritmo *InfoGainAttributeEval* (Atributos > 1.0).

4.2.9 Classificação temática e avaliação da classificação temática

Após a determinação das árvores foi selecionada para a classificação, a árvore que obteve melhor resultado, respectivamente para cada área de estudo.

A classificação é realizada para que seja possível avaliar a qualidade temática do mapa em questão. A partir da generalização das informações contidas na imagem, fez-se a comparação por validação cruzada no Software WEKA 3.8. Com base na árvore gerada, tal comparação permite verificar os valores de índice *kappa*, visto nos estudos de Congalton (1991), Foody (1992), Fonseca (2000), Bernardes (2006), Figueiredo e Vieira (2007).

5 RESULTADOS E DISCUSSÕES

5.1 Construção e classificação dos produtos cartográficos em relação ao PEC e PCD

Nas Figuras 16 e 17 são apresentados os produtos cartográficos gerados na forma de ortoimagens das áreas de estudo 1 e 2, respectivamente.

Ambas as ortoimagens foram geradas no software *Agisoft Photo Scan* versão 1.5.2. É possível observar que na Área de Estudo 1 existe uma grande quantidade de elementos sobre a imagem, devido ser a área de maior recobrimento. A quantidade significativa de elementos contribui diretamente com a forma de seleção das amostras sobre estas áreas. Na Área de Estudo 2 são observados elementos com caráter mais homogêneo, sem tanta dispersão, o que tende a facilitar a segmentação da imagem.

A resolução espacial da imagem da Área de Estudo 1 possui 0,080 metros, já a imagem da área de estudo 2 possui 0,064 metros. Essa diferença deve-se ao GSD médio calculado pelo programa para cada uma das áreas, haja vista que sobre o terreno há diferentes alturas.

Essa variação também acontece na confecção dos MDE. Normalmente, a resolução que cabe à interpolação para a geração do modelo é ainda maior. As Figuras 20 e 21 apresentam os MDE das áreas de estudo 1 e 2, respectivamente.

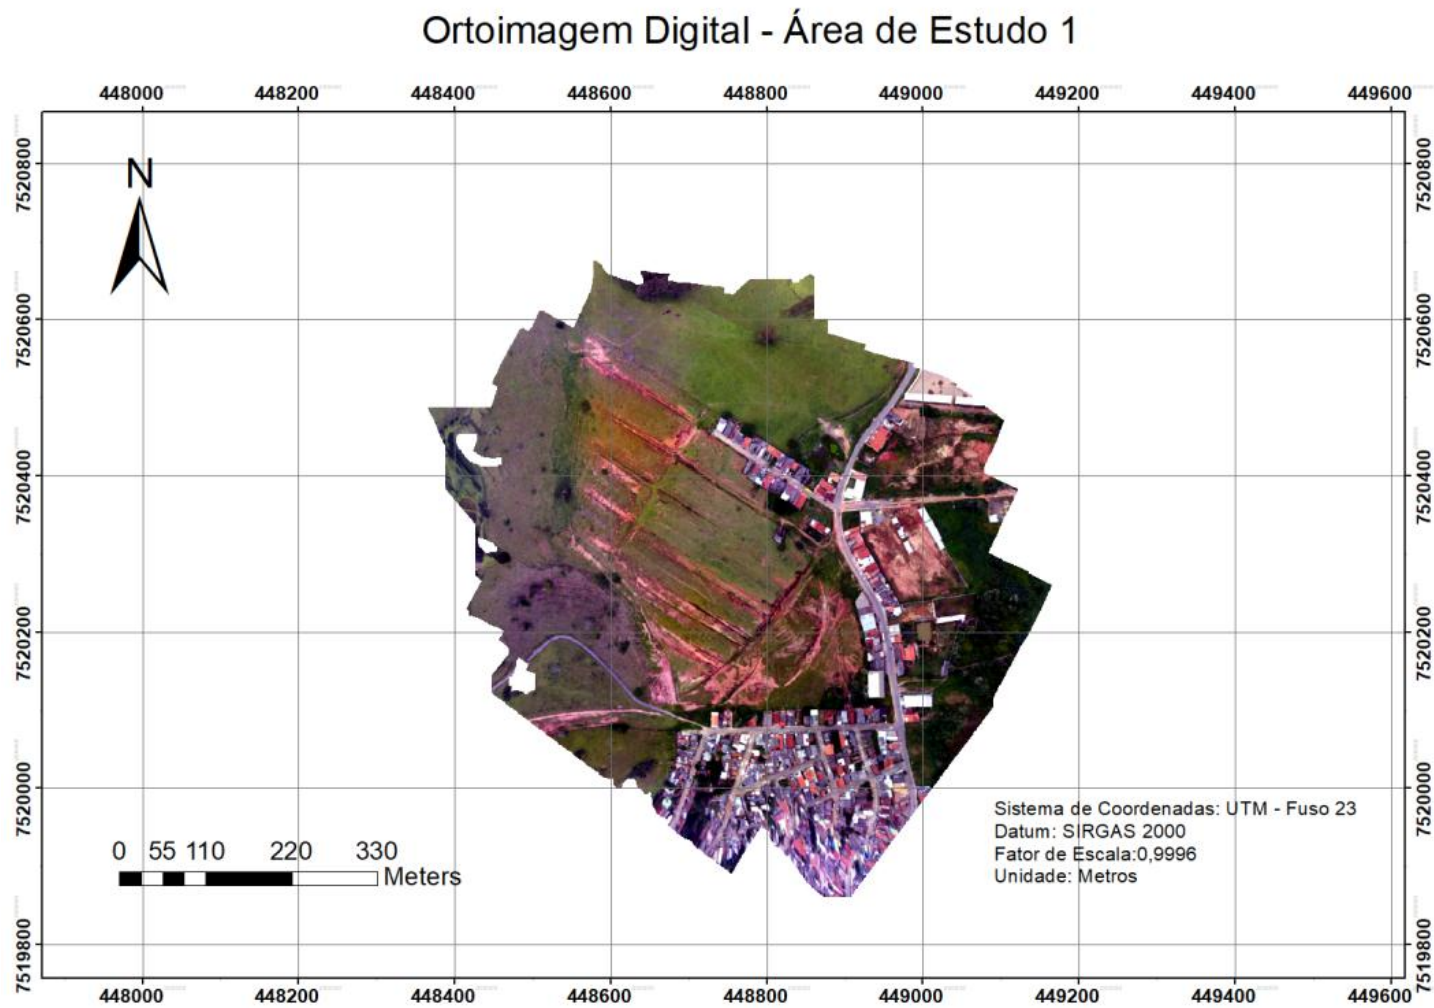


Figura 16. Ortoimagem Digital - Área de Estudo 1
Fonte: Autor (2020).

Ortoimagem Digital - Área de Estudo 2

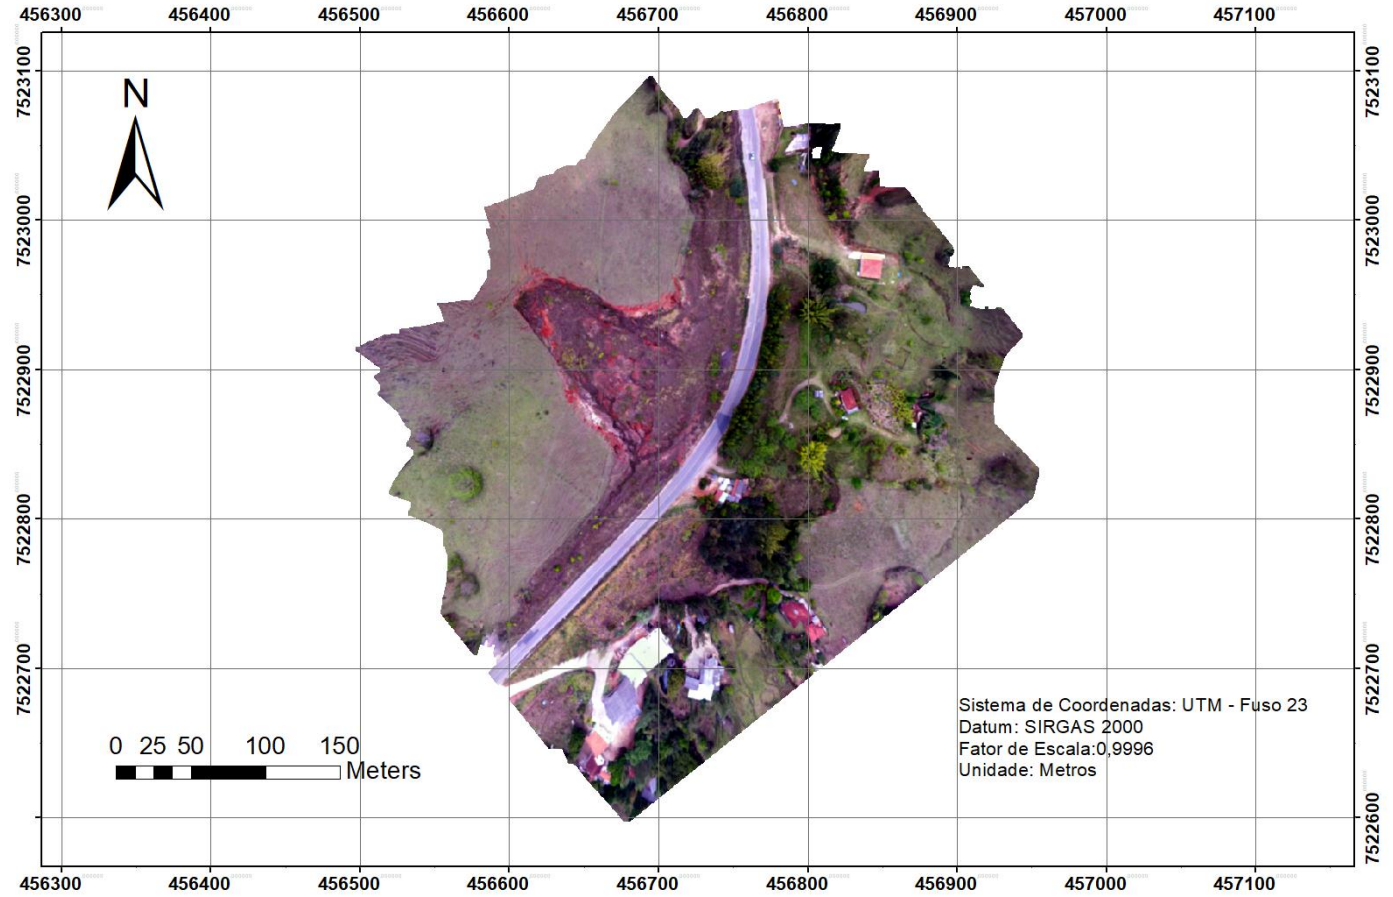


Figura 17. Ortoimagem Digital - Área de Estudo 2
Fonte: Autor (2020).

Modelo Digital de Elevação (MDE) - Área de Estudo 1

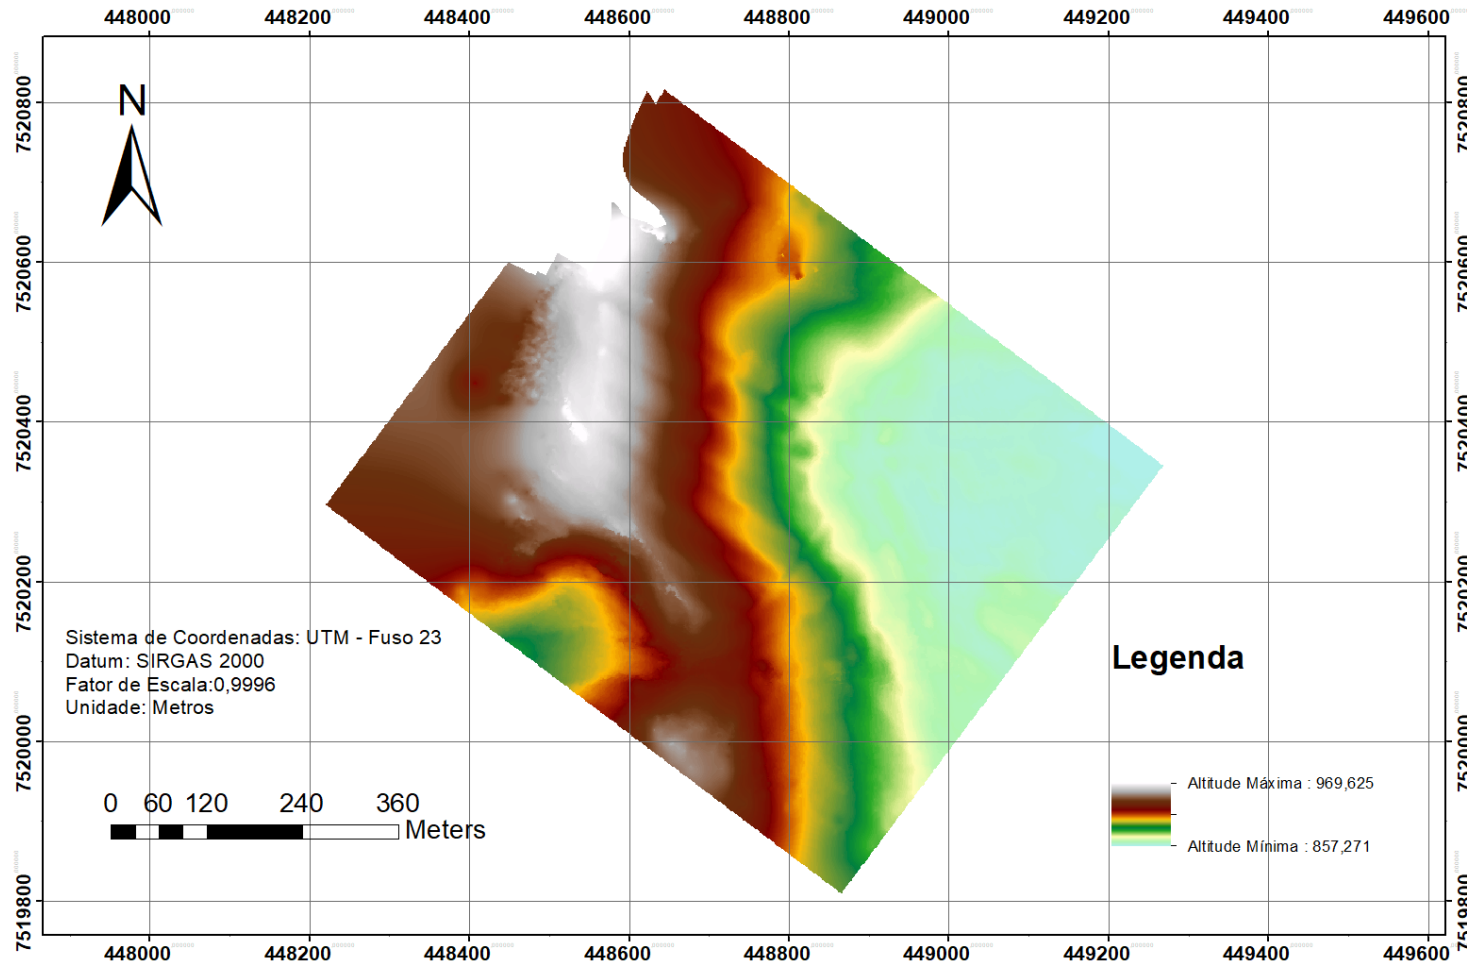


Figura 18. Ortoimagem Digital - Área de Estudo 1

Fonte: Autor (2020).

Modelo Digital de Elevação (MDE) - Área de Estudo 2

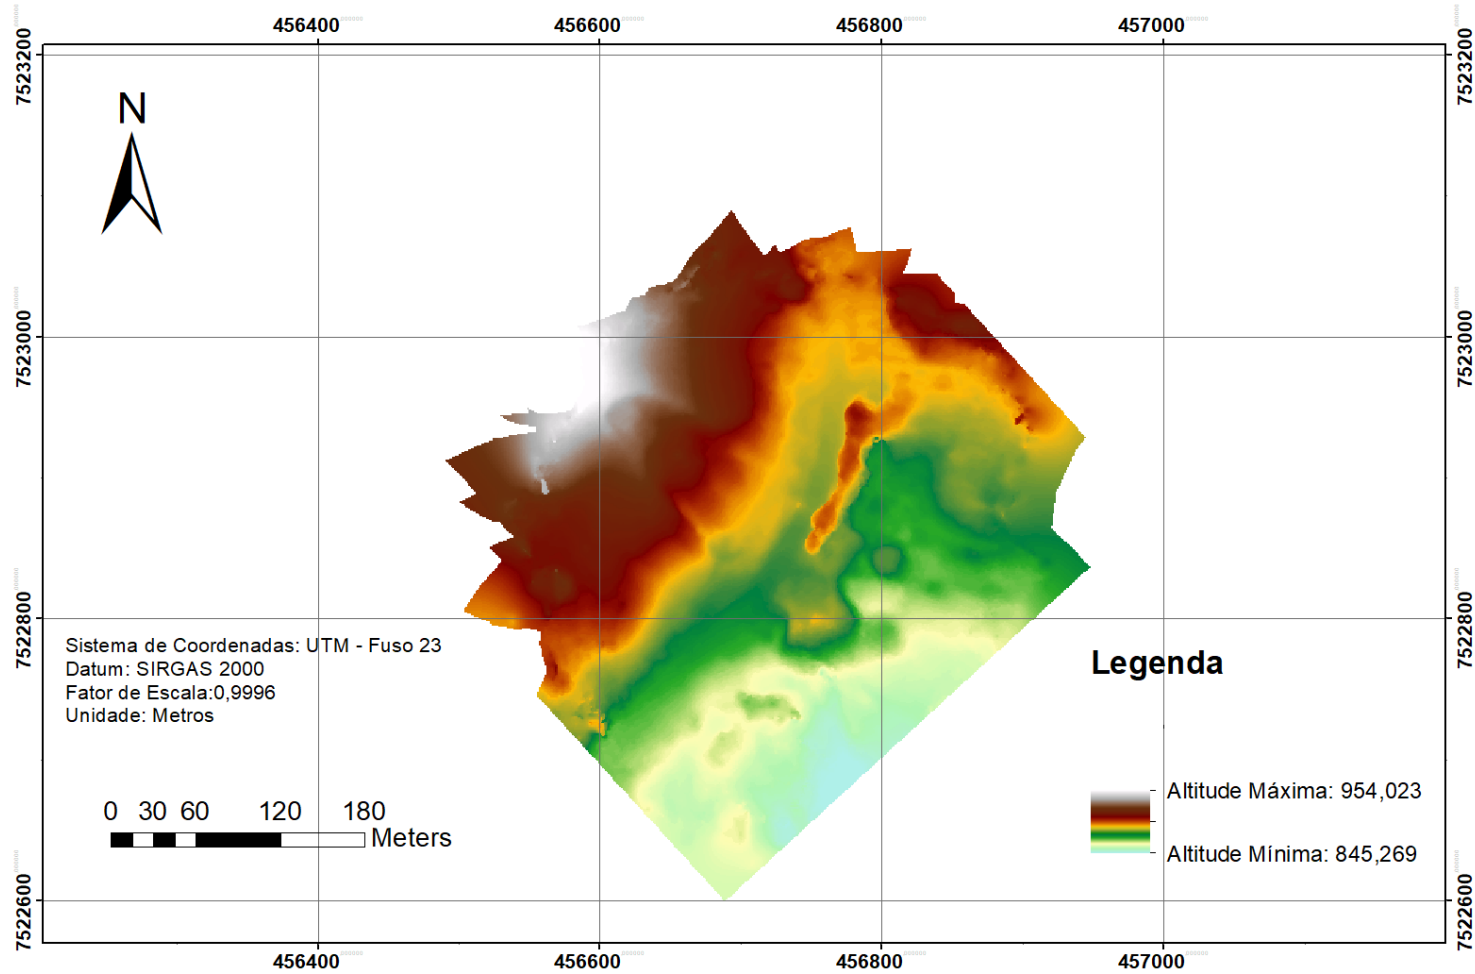


Figura 19. Ortoimagem Digital - Área de Estudo 2
Fonte: Autor (2020).

Os modelos digitais de elevação (MDE) das Áreas de Estudo 1 e 2 possuem as células com tamanho igual a 1,38 metros (Área de Estudo 1) e 1,02 metros (Área de Estudo 2). Tais valores atendem a expectativa de representação, e vale ressaltar que tais diferenças são esperadas, haja vista que se trata de áreas diferentes, apesar dos parâmetros como altura de vôo e condições da câmera se manterem para as duas áreas.

Segundo Ercole (2019), o MDE é determinante para compreender o estágio de degradação apresentado pela voçoroca, afinal, o MDE permite analisar qual a profundidade da voçoroca como também analisar qual o caminho do escoamento superficial, possibilitando um melhor planejamento das técnicas de recuperação.

Tschiedel et al. (2018) descreve que a produção de um MDE preciso é fundamental para estimar o volume de solo que fora desprendido pelo processo erosivo. Logo, ao longo do tempo, o MDE permite considerar se há evolução do processo erosivo e qual o volume de solo tem sido perdido.

Nas Tabelas 9 e 10 são apresentados os resultados da aplicação dos produtos cartográficos em relação ao PEC-PCD, para as Áreas de Estudo 1 e 2.

Tabela 9. Classificação dos produtos cartográficos e estatísticas descritivas - Área de Estudo 1.

Classe	Produto Cartográfico (Escala 1:2.000)	Estatística Descritiva		
		Média	Desvio Padrão	RMS
A	Altimetria (MDE)	0,038	0,165	0,165
A	Planimetria (Ortoimagem)	0,187	0,033	0,189

Tabela 10. Classificação dos produtos cartográficos e estatísticas descritivas - Área de Estudo 2.

Classe	Produto Cartográfico (Escala 1:2.000)	Estatística Descritiva da Discrepância entre os Pontos		
		Média	Desvio Padrão	RMS
A	Altimetria (MDE)	0,041	0,162	0,163
A	Planimetria (Ortoimagem)	0,175	0,072	0,188

Os produtos cartográficos foram classificados à classe A, na escala 1:2.000. Diante do exposto, é possível considerar que a produção de ortofotomontagens e MDE de áreas que sofreram com o processo erosivo, deve substanciar informações sobre o

estágio de degradação, bem como para o monitoramento de quais as implicações dos processos erosivos ao longo do tempo.

5.2 Geração de objetos a partir de parâmetros de segmentação

Neste tópico são apresentados os resultados da segmentação para cada área de estudo. Na Área de Estudo 1, utilizou-se primeiramente, o algoritmo *Multiresolution*, com FE= 10 (Figura 20) e, em seguida, foi utilizado o algoritmo *Spectral Difference* com Limiar de valor 1, a fim de testar os limiares.




Figura 20. Segmentação Multiresolution - FE= 10 e Spectral Difference= 1 - Área de Estudo 01.
Fonte: Autor (2020).

Na Área de Estudo 2 foram determinados os parâmetros para os algoritmos *Multiresolution* (FE= 10) e *Spectral Difference* (limiar= 1) (Figura 21).




Figura 21. Segmentação Multirresolução - FE= 10 e Spectral Diference= 1 - Área 02.
Fonte: Autor (2020).

Os resultados foram determinados a partir de uma gama de testes realizados empiricamente. Na determinação dos limiares percebeu-se que quando se determina um fator de escala maior, há um risco maior de se agregar objetos distintos. O limiar 10 para FE, nestas imagens foi satisfatório. O *Algoritmo Spectral Diference* torna o procedimento de união de agregados mais fidedigno. Espera-se que objetos sejam semelhantes, sobretudo pela semelhança espectral, por isso utilizou-se um limiar de 1 para este algoritmo. Isso quer dizer que seriam agregados em um único objeto, segmentos que tivessem uma distância euclidiana entre as bandas no valor de 1. Ambas as imagens tiveram objetos e segmentos bem coincidentes em alguns casos, podendo até agregá-los com certo nível de semelhança, no entanto, foi preferível manter os segmentos.

A escolha do parâmetro visa estabelecer a melhor forma de representar os elementos propostos no planejamento da classificação. Embora a confusão de alguns segmentos, em parte, seja inevitável, os resultados apresentados foram satisfatórios, permitindo extrair segmentos homogêneos para mineração e classificação dos dados.

5.3 Mineração de dados (Árvores de decisão e seleção de atributos)

As Tabelas de 11 a 16 apresenta o subconjunto de atributos que foram determinados a partir da seleção de atributos, e posteriormente submetidos a classificação pelo algoritmo C 4.5.

Tabela 11. Atributos determinados para a Área de Estudo 01 (*Classifier Attribute Eval*).

Classifier Attribute Eval - Área 01 - 20 Atributos
Ratio R
Ratio G
Border length
Border Contrast MDE
Border Contrast G
Min. pixel value MDT
Min. pixel value G
Min. pixel value B
Mean of outer border R
Mean of outer border G
Mean of outer border B
GLCM Homogeneity (quick 8/11) (all dir.)
GLCM Entropy (quick 8/11) (all dir.)
Length/Width
Mean of inner border MDT
Mean of inner border G
Mean B
Max. pixel value MDT
Circular Mean R (R1 Length 3 R2 Same (= R1) border)
Circular Mean B (R1 Length 3 R2 Same (= R1) border)

Tabela 12. Atributos determinados para a Área de Estudo 01 (*InfoGainAttributeEval*).

InfoGainAttributeEval - Área 01 - 10 Atributos
Ratio MDT
Ratio B
Min. pixel value B
Max. diff.
Mean of outer border G
Mean of outer border B
Mean of inner border B
Mean B
Max. pixel value B
Circular Mean B (R1 Length 3 R2 Same (= R1) border)

Tabela 13. Atributos determinados para a Área de Estudo 01 (*Principal Components*).

Principal Components - Área 01 - 12 Atributos
A = (0.189*Ratio MDE)+(0.188*Ratio MDT)+(0.188*Max. diff)-(0.182*Ratio B)-(0.181*Min. pixel value B)
B = (0.238*Max. pixel value MDT)+(0.238*Circular Mean MDT (R1 Length 3 R2 Same (= R1) border))+(0.238*Mean MDT)+(0.238*Mean of outer border MDT)+(0.238*Mean of inner border MDT)
C = (0.352*Mean of outer border MDA)+(0.352*Mean of inner border MDA)+(0.351*Circular Mean MDA (R1 Length 3 R2 Same (= R1) border))+(0.351*Mean MDA)+(0.328*Max. pixel value MDA)
D = (0.329*Border Contrast G)+(0.328*Border Contrast R)+(0.322*Border Contrast B)-(0.21*Circular Mean B (R1 Length 3 R2 Same (= R1) border))-(0.195*GLCM Homogeneity (quick 8/11))
E = (-0.352*GLCM Contrast (quick 8/11))-0.351S*tandard deviation B)-(0.35*Standard deviation G)-(0.342S*tandard deviation R)-(0.256*Length/Width)
F = (0.418*Asymmetry)+(0.413*Length/Width)+(0.373*Border length)+(0.311*Compactness)+(0.225*Standard deviation MDE)
G = (0.548*Standard deviation MDT)+(0.542*Standard deviation MDE)-(0.183Length/Width)+(0.175*Compactness)+(0.161*Standard deviation MDA)
H = (0.678*Border Contrast MDT)+(0.661*Border Contrast MDE)-(0.163*Length/Width)-(0.149*Asymmetry)-(0.133*Compactness)
I = (-0.39*Border Contrast MDA)-(0.365*Asymmetry)-(0.299*Length/Width)+(0.213*Circular Mean G (R1 Length 3 R2 Same (= R1) border))+(0.201*Mean of outer border G)
J = (-0.751*Standard deviation MDA)+(0.349*Min. pixel value MDA)+(0.243*Compactness)-(0.193*Max. pixel value MDA)+(0.169*Border Contrast MDA)
L = (-0.795*Border Contrast MDA)+(0.38*Compactness)-(0.221*Standard deviation MDE)-(0.219*Standard deviation MDT)+(0.105*Circular Mean MDA (R1 Length 3 R2 Same (= R1) border))
M = (-0.681*Compactness)-(0.314*Standard deviation MDA)-(0.31*Border Contrast MDA)+(0.257*Length/Width)-(0.194*Circular Mean G (R1 Length 3 R2 Same (= R1) border))

Tabela 14. Atributos determinados para a Área de Estudo 02 (*Classifier Attribute Eval*).

Classifier Attribute Eval - Área 02 - 10 Atributos
Ratio R
Ratio G
Ratio B
Border length
Min. pixel value MDE
Max. diff.
Mean of outer border R
GLCM Homogeneity (quick 8/11) (all dir.)
Mean of inner border G
Circular Mean B (R1 Length 3 R2 Same (= R1) border)

Tabela 15. Atributos determinados para a Área de Estudo 02 (*Info Gain Attribute Eval*).

Info Gain Attribute Eval - Área 02 - 23 Atributos
Ratio R
Ratio G
Ratio B
Min. pixel value MDT
Min. pixel value MDE
Min. pixel value B
Max. diff.
Mean of outer border MDT
Mean of outer border MDE
Mean of outer border B
GLCM Homogeneity (quick 8/11) (all dir.)
Mean of inner border MDT
Mean of inner border MDE
Mean of inner border B
Standard deviation B
Mean MDT
Mean B
Max. pixel value MDT
Max. pixel value MDE
Max. pixel value B
Circular Mean MDT (R1 Length 3 R2 Same (= R1) border)
Circular Mean MDE (R1 Length 3 R2 Same (= R1) border)
Circular Mean B (R1 Length 3 R2 Same (= R1) border)

Tabela 16. Atributos determinados para a Área de Estudo 02 (*Principal componets*).

Principal Components - Área 02 - 28 Atributos
A = -0.213Ratio MDE= -0.213Ratio MDA= -0.213Mean MDA= -0.213Standard deviation MDA= -0.213Ratio MDT= ...
B = 0.243Max. pixel value MDE+0.243Mean MDE+0.243Mean of outer border MDE+0.243Mean of inner border MDE+0.243Circular Mean MDE (R1 Length 3 R2 Same (= R1) border)...
C = -0.304Circular Mean MDA (R1 Length 3 R2 Same (= R1) border)= 2.9259432838-0.304Standard deviation MDA= 2.500834468-0.304Mean of outer border MDA= 3.3696953269-0.304Ratio MDA= 0.0013740862092-0.304Mean MDA= 3.0662970127...
D = -0.213Mean of outer border MDA= 2.9858663808-0.213Mean of inner border MDA= 3.2585638137-0.213Border Contrast MDA= 0.070156958795-0.213Mean MDA= 3.3994844081-0.213Ratio MDE= 0.42131348814...
E = -0.199Mean MDA= 3.3994844081-0.199Border Contrast MDA= 0.070156958795-0.199Ratio MDT= 0.41573863253-0.199Ratio MDE= 0.42131348814-0.199Standard deviation MDA= 1.8286054516...
F = -0.234Mean of inner border MDA= 5.6675066267-0.234Mean of outer border MDA= 4.8081359863-0.234Ratio MDE= 0.40569664158-0.234Border Contrast MDA= 0.95749511719-0.234Ratio MDA= 0.0028314548982...
G = -0.238Standard deviation MDA= 0.31949818385-0.238Mean MDA= 0.48440009857-0.238Mean of inner border MDA= 0.47143554688-0.238Circular Mean MDA (R1 Length 3 R2 Same (= R1) border)= 0.44347805447-0.238Ratio MDT= 0.40556038316...
H = -0.258Mean of inner border MDA= 1.3460218641-0.258Ratio MDT= 0.40914584829-0.258Standard deviation MDA= 0.53439855197-0.258Border Contrast MDA= -0.042856852214-0.258Ratio MDA= 0.00066322067435...
I = 0.286Ratio MDA= 0.0007934520148+0.286Standard deviation MDA= 3.6483556531+0.286Mean of outer border MDA= 3.553638805+0.286Mean of inner border MDA= 2.2096102845+0.286Ratio MDT= 0.3969356673...
J = -0.295Mean MDA= 0.016357421875-0.295Standard deviation MDA= 0.042026192636-0.295Mean of outer border MDA= 0.035238370028-0.295Ratio MDE= 0.41378866551-0.295Mean of inner border MDA= 0.027805702359...
L = -0.278Mean of inner border MDA= 0-0.278Ratio MDA= 0-0.278Mean MDA= 0-0.245Mean of outer border MDA= 0-0.193Ratio MDE= 0.4092722283...
M = 0.36 Mean MDA= 7.0060916063+0.36 Ratio MDT= 0.40957445655+0.36 Mean of inner border MDA= 6.8939941406+0.36 Ratio MDA= 0.0032490207221+0.36 Ratio MDE= 0.4151507676...
N = 0.216Min. pixel value G-0.212Standard deviation B+0.209Brightness-0.209Standard deviation R+0.202Min. pixel value B...
O = 0.442Ratio MDT= 0.40192687926+0.442Ratio MDE= 0.40761391661+0.314Border Contrast MDE-0.275Ratio MDT= 0.40301089705-0.275Ratio MDE= 0.4092722283...
P = -0.375Max. pixel value G-0.279Max. pixel value R-0.276Standard deviation B-0.267Standard deviation G-0.258Standard deviation R...
Q = -0.5Ratio MDT= 0.40559815575-0.5Ratio MDE= 0.41191230803+0.323Circular Mean MDA (R1 Length 3 R2 Same (= R1) border)= 0.22250366211+0.323Ratio MDE= 0.4092722283+0.323Ratio MDT= 0.40301089705...

R= -0.479Mean R-0.473Mean B-0.446Mean G-0.253Ratio R+0.199Ratio G...
S= -0.372Ratio R-0.348Max. pixel value R-0.296Min. pixel value R+0.283Mean R-0.275Max. diff....

Tabela 17. Atributos determinados para a Área de Estudo 02 (*Principal componets*) (continuação).

Principal Components - Área 02 - 28 Atributos
T= -0.551Mean of inner border G-0.531Mean of inner border B-0.368Mean of inner border R+0.251Border Contrast MDT-0.147Border Contrast B...
U= 0.469Mean of outer border G+0.465Mean of outer border R+0.452Border Contrast B+0.261Mean of outer border B+0.211Ratio R...
V= 0.407Circular Mean G (R1 Length 3 R2 Same (= R1) border)+0.398Length/Width+0.344Circular Mean R (R1 Length 3 R2 Same (= R1) border)+0.341Circular Mean B (R1 Length 3 R2 Same (= R1) border)-0.255Asymmetry...
X= 0.508Border Contrast MDT-0.433Standard deviation MDT-0.312Standard deviation MDE-0.292Border length+0.282Border Contrast MDE...
Y= 0.682Compactness+0.502Border Contrast G+0.29 Mean of inner border R+0.202Length/Width-0.165Circular Mean R (R1 Length 3 R2 Same (= R1) border)...
A1= -0.576Length/Width+0.433Compactness+0.406Circular Mean B (R1 Length 3 R2 Same (= R1) border)+0.348Circular Mean R (R1 Length 3 R2 Same (= R1) border)+0.276Mean of outer border B...
B1= -0.581Mean of outer border B+0.469Mean of outer border R+0.296Circular Mean B (R1 Length 3 R2 Same (= R1) border)-0.253Length/Width-0.215Circular Mean R (R1 Length 3 R2 Same (= R1) border)...

A Tabela 17 apresenta os resultados da matriz confusão e seu respectivo índice de Exatidão Global (índice Kappa) obtidos para as árvores de decisão. Foram geradas 4 árvores de decisão para cada área de estudo, utilizando o algoritmo C 4.5 e o respectivo algoritmo de seleção de atributos. Na Tabela 17 são apresentados os resultados obtidos em relação aos algoritmos de seleção de atributos.

Tabela 18. Resultados das árvores de decisão das Áreas de Estudo.

Área de Estudo	Algoritmo da Árvore de Decisão	Algoritmo de Seleção de Atributos	Quantidade de Atributos	Exatidão Global
1	C 4.5	Sem Algoritmo	64	0.92
1	C 4.5	ClassifierAttributeEval.	20	0.9173
1	C 4.5	PrincipalComponents	12	0.8105
1	C 4.5	InfoGainAttributeEval	10	0.8385
2	C 4.5	Sem Algoritmo	64	0.8936
2	C 4.5	ClassifierAttributeEval.	10	0.8934
2	C 4.5	PrincipalComponents	28	0.8713
2	C 4.5	InfoGainAttributeEval	23	0.8801

É possível verificar na tabela, que a partir dos valores do índice Kappa para cada árvore de decisão. Foram escolhidas, para cada área de estudo, as árvores que apresentaram o melhor resultado, sendo estas submetidas à classificação temática. As árvores que apresentaram melhores resultados foram às árvores que utilizaram os maiores números de atributos. É possível inferir, a partir de estudos como o de Anjos (2016), que o número de atributos está diretamente ligado à precisão da árvore, ou seja, quanto mais atributos se tenham, uma maior chance de ter melhores resultados existe.

5.4 Classificação Temática

A seguir são apresentadas a classificação temática das Áreas de Estudo 1 e 2 (Figura 22 e 23).





Figura 22. Classificação temática Área de Estudo 01.
Fonte: Autor (2020).





Figura 23. Classificação temática da Área de Estudo 2.
Fonte: Autor (2020).

As tabelas 18 e 19, apresentam as matrizes confusão, referente à classificação temática das áreas de estudo 1 e 2.

Tabela 19. Matriz de confusão Área de Estudo 01.

Matriz Confusão - Área 01 - (Kappa = 0.92)							
a	b	c	d	e	f	g	Classes
72	1	1	0	0	0	0	a = Vegetação Rasteira
0	398	0	1	3	2	6	b= Voçoroca
0	0	57	3	1	0	0	c= Asfalto
0	0	1	93	2	1	0	d= Telhado de Fibrocimento/Metalica
1	2	4	2	74	9	0	e= Solo Exposto
0	3	0	2	3	78	0	f= Telhado de amianto
5	6	0	0	0	0	151	g= Vegetação Arbórea

Tabela 20. Matriz de confusão Área de Estudo 02.

Matriz Confusão - Área 02 - (Kappa = 0.8936)						
a	b	c	d	e	f	Classes
41	0	0	0	2	0	a = Vegetação Rasteira
0	34	0	0	0	2	b = Rodovia
1	0	41	0	0	0	c = Vegetação Arbórea
0	1	0	52	4	1	d = Voçoroca
3	0	0	2	46	1	e = Vegetação presente na Voçoroca
0	3	0	3	1	34	f = Solo Exposto

Pela matriz confusão da área 01, podemos verificar que há uma confusão entre as classes: Solo Exposto e Telhado de Amianto, Voçoroca e Vegetação Arbórea, Solo Exposto e Asfalto, e entre Vegetação Arbórea e Vegetação rasteira. Destacam-se essas confusões como as mais significativas. Vale ressaltar que quando se aplica o algoritmo Spectral Difference, alguns segmentos, com maior nível de semelhança, se juntam formando um único segmento, maior. Este efeito faz com que, quando houver uma confusão entre classes, na matriz confusão, embora apareça um único segmento de confusão, este capaz de compreender uma grande área.

Na área 2, destaca-se as confusões entre as classes: Voçoroca e Vegetação Presente na Voçoroca, Solo Exposto e Voçoroca, Solo Exposto e Rodovia. Vale ressaltar que nesta imagem também há o mesmo efeito, da união dos segmentos, visto a aplicação do Spectral Difference nas duas áreas.

Apesar do índice kappa ter sido com um valor de concordância quase perfeita ($kappa > 0,8$), visto nos estudos de Congalton (1991), Foody (1992), Fonseca (2000), Bernardes (2006), Figueiredo e Vieira (2007). Podemos entender que uma amostra pode compreender uma área maior que outra, fazendo com que possa haver uma confusão significativa mesmo em poucas unidades de segmentos.

Na Figura 22, como dito na seção 5.1, existem uma heterogeneidade maior dos seguimentos. Tal fato contribuir para que haja uma dispersão na confusão espectral, pois há seguimentos com características distintas, porém muito próximas. Não se pode afirmar que este é o fator principal de confusão, mas é um dos que tornam a classificação mais complexa. Ainda, na figura 22, é possível ver que algumas confusões entre Asfalto e Telhado de Fibrocimento/ Metálica foram as mais comuns por ambos possuírem cores acinzentadas, porém na matriz confusão aparecem com um número de amostras pequenas. Isso se dá devido aos segmentos do asfalto ser mais uniformes. Houve pouca confusão entre telhados de amianto e solo exposto, apesar de aparecerem em mesma cor. Tal efeito pode se dar ao modelo digital de altura que diferencia estes dois termos. A pastagem se mostrou a mais homogênea das classificações. A voçoroca e solo exposto, apesar das características espectrais bem parecidas, foram bem discriminados, não havendo uma confusão significativa no objeto de estudo. Os resultados para esta área foi de um índice de exatidão global de 0,92(92%).

Na Figura 23 é possível observar uma classificação bem mais homogênea em relação a figura 22. A construção dos segmentos foram realizados da mesma forma (com os mesmos parâmetros), porém é possível ver resultados distintos. Isso se dá pelas áreas do objeto de estudo possuir características diferentes, apesar de ser o mesmo tipo de objeto de estudo. Ressalta-se aqui, a complexidade de um padrão para delimitar um tipo específico de objeto de estudo, como a voçoroca. Apesar de teoricamente as características serem bem definidas, na prática existe uma complexidade na interpretação computacional no que tange ao processamento digital de imagens. Nota-se que há uma pequena confusão entre asfalto e voçoroca. A maior confusão ficou dentro das classes de vegetação presente na voçoroca, porém, ambas as classes modelam o elemento voçoroca e isso faz com que não seja um problema. A pastagem e a vegetação

arbórea se mostraram bem definidas e sem significativas confusões entre si. O índice de Exatidão global (Kappa) desta área foi de 0,89 (89%).

Com base nos estudos de Longhitano et al. (2016), Ercole (2019) e Silva (2016), pode-se considerar, pelos produtos obtidos, que é possível garantir uma boa delimitação do elemento de estudo, com uma margem de erro que não prejudica a qualidade do resultado. A aplicação de técnicas de mineração de dados combinadas a procedimentos de GEOBIA em imagens oriundas de ARP apresentam bons resultados, no que tange a delimitação de voçorocas.

6 CONSIDERAÇÕES FINAIS

As definições da área de estudo foram positivas, uma vez que foi possível a identificação das voçorocas presentes nas áreas de estudo. Ao considerar que as áreas degradadas possuem características distintas, onde a Área de Estudo 1 apresenta uma voçoroca menos homogênea, em área urbana, derivada de ruas de loteamento abertas e abandonadas e a Área de Estudo 2 encontra-se em área rural, com o elemento voçoroca mais homogêneo e proveniente de atividades agrossilvopastoris, é possível afirmar que a metodologia proposta neste estudo foi efetiva para a determinação de existência da voçoroca.

Deve-se salientar que ambas as áreas foram bem delimitadas pelas imagens obtidas e, por consequência, os produtos cartográficos apresentaram uma boa classificação em relação aos padrões PEC-PCD.

Destaca-se a qualidade posicional dos produtos cartográficos gerados com *Phantom4*, o qual é um produto de baixo custo em relação a outras fontes de obtenção de informações, apresentando grande capacidade de obter dados com precisão planimétrica e altimétrica.

Ainda é importante salientar que a coleta de dados com receptores GNSS com as portadoras L1/L2 permitiu obter a precisão da coleta das coordenadas dos pontos de controle da ordem centimétrica. Isso contribuiu com a validação dos produtos cartográficos em relação ao PCD, bem como na construção dos próprios produtos cartográficos. Essas etapas são primordiais para garantir que o objetivo do trabalho seja cumprido.

Os parâmetros de segmentação de imagens apresentados se mostraram suficientes para a discriminação das classes propostas no planejamento da classificação. A combinação dos algoritmos *Multiresolution* e *Spectral Difference* permitiu obter um resultado significativo em termos de homogeneização dos segmentos, facilitando a coleta de amostras para a classificação e mineração dos dados.

A extração de atributos é uma abordagem essencial dentro do trabalho proposto, visto que existe uma grande gama de atributos no software utilizado, havendo infinitas possibilidades de obter informações sobre um determinado objeto.

A mineração de dados tem duas etapas primordiais, sendo a primeira, a seleção dos atributos mais relevantes, mediante o ranqueamento proposto pelos algoritmos existentes no *software* WEKA 3.8. A segunda etapa é a aplicação do algoritmo C 4.5

sobre esses atributos, a fim de que fosse gerada a árvore de decisão. Foi possível perceber que existe uma relação entre número de atributos e com a precisão da árvore. Alguns estudos afirmam esta relação no sentido de que, quanto mais atributos existem em uma árvore, maior será a sua precisão, chegando a um nível de estagnação, denominado efeito *Hughes* (HUGHES, 1968).

A delimitação de voçorocas por meio de GEOBIA e mineração de dados, utilizando os produtos cartográficos de ARP, é satisfatória a um determinado nível de classificação. A resolução espacial e espectral (RGB) dos produtos cartográficos de ARP tem um bom papel na segmentação de objetos, permitindo que, conseqüentemente, sejam extraídos atributos com mais fidedignidade. A abordagem GEOBIA é bem adequada para aplicações com os produtos derivados de ARP.

A mineração de dados (seleção de atributos e árvores de decisão), por sua vez, é uma ferramenta que oferece uma classificação a partir de regras. Implica que com mais parâmetros é possível determinar modelos de classificação para voçorocas. Sendo a voçoroca um elemento de natureza complexa, tanto pela sua definição quanto por suas características físicas, resultados desta natureza seriam de grande valia para os órgãos ambientais do país.

Por fim, pode-se considerar que esta pesquisa colabora com a literatura, podendo, ser continuada com a realização de estudos mais complexos sobre esta temática, os quais futuramente permitirão obter resultados mais robustos no que tange a delimitação de áreas degradadas do tipo voçoroca, utilizando imagens oriundas de ARP. É possível delimitar voçorocas por meio de GEOBIA e mineração de dados, utilizando produtos cartográficos oriundos de ARP.

7 REFERÊNCIAS

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **Instrução Suplementar - IS Nº 21-002.2012**. Disponível em: <http://www2.anac.gov.br/biblioteca/IS/2012/IS%2021-002A.pdf> . Acesso em: 01 nov. 2012.

AIMON, J.G.S. et al. Geotecnologias aplicadas para mapeamento de processos erosivos: estudo de caso voçoroca do Ijuízinho. In: Congresso Brasileiro de Cadastro Técnico Multifinalitário e Gestão Territorial, 10. **Anais...** Florianópolis: COBRAC. 2018. P.1-13.

ALBERTZ, J.; KREILING, W. **Photogrammetrisches Taschenbuch**. 4.ed. Wichmann: Karlsruhe, 1989.

ALMEIDA, J. F. **Ortoimagem Digital**. 1989. 103 f. Dissertação (Mestrado), Universidade Federal do Paraná, Curitiba, 1989.

ALVES, R.R. **Monitoramento dos processos erosivos e da dinâmica hidrológica e de sedimento de uma voçoroca**: Estudo de caso Fazenda do Glória na Zona Rural de Uberlândia MG. 2007. 109 f. Dissertação (Mestrado) - Curso de Geografia, Instituto de Geografia, Universidade Federal de Uberlândia, Uberlândia, 2007.

ANDRADE, J. B. **Fotogrametria**. Curitiba: SBEE, 1998. 258p.

ANJOS, C. S. dos. **Classificação de áreas urbanas com imagens multiespectrais e hiperespectrais utilizando métodos não-paramétricos**. 2016. 382 f. Tese (Doutorado) - Curso de Pós Graduação em Sensoriamento Remoto, Inpe, São José dos Campos, 2016.

ANTUNES, A. F. B. et al. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. 147 p. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2003.

ARAUJO, G. H. S.; ALMEIDA, J. R.; GUERRA, A. J. T. **Gestão Ambiental de Áreas Degradadas**. Rio de Janeiro: Editora Bertrand Brasil, 2005. 320 p.

BAATZ, M.; SCHÄPE, A. **Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation**. 2000. Acesso online. Disponível em: http://www.ecognition.com/sites/default/files/405_baatz_fp_12.pdf. Acesso em 29 jan 2020.

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

BATISTA, P.V.G. et al. Estimativa do volume de erosões do tipo sulcos e deslocamento de massa utilizando imagens 3D, obtidas por Veículo Aéreo Não Tripulado. In: Congresso Brasileiro de Ciência do Solo, 35. **Anais...** Natal: CBCS. 2015. p.1-15.

BENTO, B. M. P. **Avaliação de classificadores por árvore de decisão e árvore de regressão em cenas urbanas do sensor worldview-2**. 2017. 140 f. Dissertação

(Mestrado) - Curso de Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais - Inpe, São José dos Campos, 2017.

BERNARDES, T. **Caracterização do ambiente agrícola do Complexo Serra Negra por meio de sensoriamento remoto e sistemas de informação geográfica.** Dissertação (Mestrado). Universidade Federal de Lavras, Minas Gerais, 2006, 119p.

BERTALAN, L; TÚRI, Z.; SZABÓ, G. Uas photogrammetry and object-based image analysis (GEOBIA): erosion monitoring at the Kazár Badland, Hungary. **Landscape & Environment**, Debrecen, v. 10, n. 0, p.169-178, 2016.

BERTONI, J.; LOMBARDI NETO, F. **Conservação do Solo.** 4ª ed., São Paulo: Ícone. 355p., 1999.

BHATTACHARYYA, A. On a measure of divergence between two statistical populations defined by their probability distributions. **Bulletin of the Calcutta Mathematics Society**, v.35, n.1, p. 99–110, 1943.

BLASCHKE, T. et al. Geographic Object-Based Analysis: Towards a new paradigm. **Isprs Journal of Photogrammetry and Remote Sensing**. Salzburg, Austria, p. 1-13. jan. 2014.

BLASCHKE, T.; STROBL, J. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. **GIS**. Salzburg, Austria, p. 12-17. jan. 2001.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. Object oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. **Environmental information for planning**, Metropolis Verlag v. 2, p. 555-570, 2000.

BRASIL, J. et al. “Voçoroca”: Estudo de Caso de Monitoramento e Análise de Solo em São Desidério-BA. In: VIII SIMPÓSIO NACIONAL DE GEOMORFOLOGIA, 8., 2010, Recife Pe. **Anais...** Recife -PE UFPE, 2010. p. 01 - 15.

BRASIL. **Estabelece as Instruções Reguladoras das Normas Técnicas da Cartografia Nacional.** 1984. Decreto Lei 89.817, 1984. Disponível em: <http://www.planalto.gov.br/ccivil_03/decreto/1980-1989/D89817.htm>. Acesso em: 29 jan. 2020.

CÂNDIDO, A. K. A. A.; SILVA, N. M. da; PARANHOS FILHO, A. C. **Imagens de Alta Resolução Espacial de Veículos Aéreos Não Tripulados (VANT) no Planejamento do Uso e Ocupação do Solo.** Anuário do Instituto de Geociências - UFRJ. Rio de Janeiro, p. 147-156. jan. 2015.

CHUBEY, M. S.; FRANKLIN, S. E.; WULDER, M. A. Object-based Analysis of Ikonos-2 Imagery for Extraction of Forest Inventory Parameters. **Photogrammetric Engineering & Remote Sensing**, v. 72, nº 4, p. 383-394, 2006.

CONCEIÇÃO, J.R. **Metodologia para identificação de áreas prioritárias para redução da erosão hídrica em bacias de mananciais de abastecimento público do Paraná:** Estudo de Caso Bacia do Passaúna. 94 f. Dissertação (Mestrado em Meio Ambiente Urbano e Industrial). Universidade Federal do Paraná, Curitiba. 2014.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data.** *Remote Sensing of Environment*, v. 49 n. 12, p. 1671-1678, 1991.

DAS, S. (2001). **Filters, wrappers and a boosting based hybrid for feature selection.** In International Conference on Machine Learning, pages 74–81. Williams College.

DEFINIENS. **Definiens Developer 7:** reference book. Munique: Definiens AG, 2007. 195 p. Disponível em: <<http://www.ecognition.cc/download/ReferenceBook.pdf>>. Acesso em: 14 jul. 2019.

DLAMINIET, P., ORCHARD, C., JEWITT, G., LORENTZ, S., TITSHALL, L., CHAPLOT, V. Controlling factors of sheet erosion under degraded grasslands in the sloping lands of KwaZulu - Natal, South Africa. **Agr. Water Manag.**, v. 98, p.1711–1718, 2011.

D’OLEIRE-OLTMANN, S., EISANK, C., DRĂGUȚ, L.; SCHROTT, L.; MARZOLFF, I.; BLASCHKE, T. Object-based landform mapping at multiple scales from digital elevation models (DEMs) and aerial photographs. **Proceedings of the 4th GEOBIA**, Rio de Janeiro, v.7.n.9, p.496-500, 2012.

D’OLEIRE-OLTMANN, S.; MARZOLFF, I.; BLASCHKE, T. **Gully Mapping on Multiple Scales Based On UAV and Satellite Data.** In: Deutschen Gesellschaft für Photogrammetrie, Fernerkundung und Geoinformation, 24. 2015.

DUNTEMAN, G. H. **Principal components analysis.** Sage University paper series on quantitative applications in the social sciences, Newbury Park, CA, USA, 1999.

ERCOLE, R.F. **Estudo dos processos erosivos em uma área de diretrizes especiais de Nova Lima, Minas Gerais com uso de veículo aéreo não tripulado.** 128 f. Dissertação (Mestrado). Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte – MG. 2019.

ESPINDOLA, G. M. CAMARA, G. **Ajuste de parâmetros no algoritmo de segmentação de imagens do software eCognition®.** In: Simpósio Brasileiro de Sensoriamento Remoto, 13. (SBSR), 2007, Florianópolis, SC. Anais... São José dos Campos: INPE, 2007. p. 5739-5744.

LEACHTENAUER, J. C; DRIGGERS, R. G. **Surveillance and reconnaissance imaging systems: Modeling and performance prediction.** Norwood: Artech House, 2001. 387 p.

DRIGGERS, Ronald G. **Encyclopedia of Optical Engennering.** 2. ed. Nova York: Marcel Dekker, 2003. 1023 p. DUDA, R.O., Hart P.E. & Stork D.G. **Pattern Classification.** 2 ed. New York: Wiley. 2001.

ELACHI, C. **Introduction to the physics and techniques of remote sensing.** Nova York: John Wileyand Sons, 1987. 413p.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. **Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto.** In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais Eletrônicos... Florianópolis: INPE, 2007. p. 5755-62.

FLAUZINO, B. K. **Degradação do solo pela erosão hídrica e capacidade de uso em sub-bacia hidrográfica piloto no sul de Minas Gerais.** 105 p. Dissertação (Mestrado em Meio Ambiente e Recursos Hídricos), Universidade Federal de Itajubá, Itajubá-MG, 2012.

FONSECA, L. M. G. **Processamento digital de imagens.** Instituto Nacional de Pesquisas Espaciais (INPE), 2000. 105p.

FOODY, G. M. **On the compensation for chance agreement in image classification accuracy assessment.** Photogrammetric Engineering and Remote Sensing, v. 58, n. 10, p. 1459-1460, 1992.

GIOVANINI JUNIOR, N. **Análise e aplicação de metodologias de predição de processos erosivos utilizando SIG na Bacia Hidrográfica do Córrego do Engano, Nova Canaã Paulista – SP.** 177 f. Dissertação (Mestrado em Engenharia Civil), Faculdade de Engenharia de Ilha Solteira – UNESP, Ilha Solteira. 2019.

GOLDSCHMIDT, R.; PASSOS, E. **Data mining – um guia prático.** Rio de Janeiro: Elsevier, 2005. 257 p.

GREGÓRIO, M.N; ALVES, F.P; SILVA, D.L. **Uso do geoprocessamento no monitoramento de controle de erosão em área de instabilidade de encostas: barragem Barra de Guabiraba- PE.** In: Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação, 5., 2014, Recife – PE. p. 339 - 345.

GUERRA, A. J. T.; BOTELHO, R. G. M. **Erosão dos Solos.** In: CUNHA, S. B. (Org.); GUERRA, A. J.T. (Org.). **Geomorfologia do Brasil.** 2. ed. Rio de Janeiro: Bertran Brasil, 2001. p. 181-227.

HAY, G. J.; CASTILLA, G.. **Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline.** *Lecture Notes in Geoinformation And Cartography*, v. u, n. u, p.75-89, 2008.

HAN, J., Kamber, M., and Pei, J. (2011). **Data mining: concepts and techniques.** Morgan Kaufmann, California, United States of America, 3 edition.

Hughes, G. F. 1968. **On the mean accuracy of statistical pattern recognizers.** *IEEE Trans. Inform. Theory*, vol. IT-14, 55-63,

IRIZARRY, J.; GHEISARI, M.; WALKER, B. N. **Usability assessment of drone technology as safety inspection tools.** *Electronic Journal of Information Technology in Construction*, Irirary, v.17, p. 194–212, 2012.

KÄMPF, N.; MARQUES, J.J.; CURI, N. Mineralogia dos solos Brasileiros. In: KER, J. C.; SCHAEFER, C. E. G. R.; VIDAL-TORRADO, P., eds. **Pedologia: Fundamentos**. Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2012. cap. 7, p. 82-128.

KRAUS, K. **Photogrammetry: fundamentals and standard processes**. 4.ed. Bonn: Dümmler, v.1, 1993.

LACERDA, M. G. et al. Influência dos parâmetros de segmentação de imagens em ortoimagemmosaicos confeccionados a partir de fotografias obtidas por aeronaves remotamente pilotadas de pequeno porte. In: Simpósio Brasileiro de Sensoriamento Remoto, 19. 2019.

LAL, R. Soil degradation by erosion. Land Degrad. **Land Degrad. Develop**, v.12, n.1, p. 519-539, 2001.

LEAL, P. C. B.; RODRIGUES, S. C. Uso e comparação do método de estaqueamento, o método DGPS e geoprocessamento no monitoramento de uma área erosiva na Fazenda do Glória – Uberlândia-MG. **GEOUSP – Espaço e Tempo**, São Paulo, n. 29, p. 18-35, 2011.

LONGHITANO, G.A. **VANTS para sensoriamento remoto: aplicabilidade BA avaliação e monitoramento de impactos ambientais causados por acidentes com cargas perigosas**. 163 f. Dissertação (Mestrado em Engenharia dos Transportes – geoprocessamento). Universidade de São Paulo, São Paulo 2010.

LONGHITANO, G.A. et al. **As contribuições associadas ao uso de vants para monitoramento da evolução de processos erosivos em Sonora-MS**. 2016. Acesso online. Disponível em: http://docs.fct.unesp.br/eventos/ypss/temp/P4_YPSS_2016_Juliana_Mantovani.pdf. Acesso em 30 jan 2020.

LOUREIRO; GUERRA. **Monitoramento de Voçorocas: Adaptações Metodológicas no uso de Estacas e Pinos de Erosão**. In: Simpósio Nacional de Geomorfologia. **Anais...** Rio de Janeiro: 2012. p. 1 - 4.

Ma, Z., R, R. L. **Tau coefficients for accuracy assessment of classification of remote sensing data**. Photogrammetric Engineering and Remote Sensing, v. 61, n. 4, p. 435-439, 1995.

MAIMOM, O.; ROKACH, L. **Data mining and knowledge discovery handbook**. 2^a ed. USA: Springer, 2010.

MARTIN, L. **PEC, O QUE É E COMO APLICAR?** 2019. Acesso online. Disponível em: <http://www.engesat.com.br/pec-o-que-e-e-como-aplicar-2/>. Acesso em: 30 maio 2019.

MITRA, P., MURTHY, C. A., and PAL, S. K. (2002). Unsupervised feature selection using feature similarity. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(3):301–312.

NAVULUR, K. **Multispectral Image Analysis Using the Object-Oriented Paradigm**. Boca Raton, Eua: Crc Press, 2007. 153 p.

NOVO, E. M. L. M. **Sensoriamento Remoto: princípios e aplicações**. São Paulo: Edgard Blucher, 2010. 388p.

OLIVEIRA, J. A; DUTRA, L. V; RENNÓ, C. D. **Aplicação de métodos de extração e seleção de atributos para classificações de regiões**. In: XII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. **Anais...** Goiânia: Inpe, 2005. p. 4201 - 4208.

OLIVEIRA, J. B. **Pedologia Aplicada**. 4ª ed. Piracicaba: Fealq, 2011. 592 p.

PARMEZAN, A.R.S. **Avaliação de Métodos para Seleção de Atributos Importantes para Aprendizado de Máquina Supervisionado no Processo de Mineração de Dados**. 2012. Disponível em: http://sites.labic.icmc.usp.br/aparmezan/publications/pdf/BIBLIOTECA_000_RT_002.pdf. Acesso em: 06 abr. 2020.

POESEN, J. et al. Gully erosion and environmental change: Importance and research needs. **Catena**, v. 50, n.2, p. 91-133, 2003.

PRATT, W. K., **Digital Image Processing**, 2ª ed. Wiley: Interscience, 1991.

PRATT, W. K. **Introduction to Digital Image Processing**. Boca Raton, EUA: CRC Press, 2007. 750 p.

QUINLAN, J. R. **C4.5: programs for machine learning**. San Mateo: Morgan Kaufmann Publishers, 1993, 300p.

REMONDINO, F.; BARAZZETTI, F.; NEX, M.; SCAIONI, M.; SARAZZI, D. UAV Photogrammetry for Mapping and 3D Modeling – Current Status and Future Perspectives. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v.38, pp. 25-31, 2011, Zurich, Switzerland. Proceedings.

ROSA, R. **Introdução ao geoprocessamento**. Uberlândia: Universidade Federal de Uberlândia, 2013. 142 p.

SARAIVA, V.I.C.; SILVA, A.S.; SANTOS, J.P.C. **Uso do mapa de solos como subsídio para definição de áreas de suscetibilidade à erosão na bacia hidrográfica São João, Lagos e Una**. GEO UERJ, Rio de Janeiro, n. 29, p. 354-373, 2016.

SAMPAIO, T. V. M.; BRANDALIZE, M. C. B. **Cartografia Geral, Digital e Temática. Série Geotecnologias: teoria e prática**; v. 1 - Curitiba: Universidade Federal do Paraná, Programa de Pós-Graduação em Ciências Geodésicas, 2018.

SILVA NETO, M. **Planejamento de voo: tudo o que você precisa**. 2015. Disponível em: Acesso em: 10 fev. 2020.

SHRUTHI, R.B.V. et al. **Quantifying temporal changes in gully erosion areas with object oriented analysis**. *Catena*, p.262-277, jan. 2015.

SIEBERT, S; TEIZER, J. **Mobile 3d mapping for surveying earthwork using an unmanned aerial vehicle (uav)**. Atlanta, v.32, n.12, p.1-9, 2014.

SILGUEIRO, V.F. et al. **Uso de imagens obtidas com veículo aéreo não tripulado (VANT) para verificação do indicador de cobertura do solo no monitoramento da restauração florestal.** In: Simpósio Brasileiro de Sensoriamento Remoto. **Anais...** Santos-SP, 2017. p. 01 - 08.

SILVA, H.J. **Análise multitemporal da expectativa da perda de solo e suas implicações na Serra da Mantiqueira.** 2016. 171 f. Dissertação (Mestrado), Universidade Federal de Itajubá, Itajubá - MG, 2016.

SILVA, M.B. **Uso de VANT para a adequação ambiental e restauração de áreas degradadas do uso do solo em propriedades rurais: “Estudo de caso em uma propriedade rural no município de Dourados-MS”.** Monografia (Especialização). Universidade Federal do Paraná, Curitiba – PR. 2016.

SOUSA, A.T.; FERREIRA, I.M. Diagnóstico de voçorocas em área de pastagem no município de Morrinhos (GO). **Espaço em revista**, São Paulo, v. 19, n. 2. , p.68-85, 2017.

SOUZA, U.D.V; KUX, H.J.H. 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**, Rio de Janeiro, v. 66, n. 3, p.433-450, jan. 2014.

SOUZA, J.T. **Métodos de seleção de atributos e análise de componentes principais: um estudo comparativo.** 2017. 73 f. Dissertação (Mestrado em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2017.

TAN, P. N.; STEINBACH, M.; KUMAR, V. **Introdução ao DATA MINING - mineração de dados.** Rio de Janeiro: Ciência Moderna, 900 p., 2009.

TEDESCO, A. **Delimitação de voçoroca com imagens de alta resolução e ALSs por meio de árvore de decisão e geobias.** 188 f. Dissertação (Mestrado em Geomática), Universidade Federal do Paraná, Curitiba, 2015.

TEIXEIRA, W. et al. (Org). **Decifrando a Terra.** São Paulo: Companhia Editora Nacional, 2009.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition.** USA: Academic Press. 1999.

TOLEDO, B. et al. **Análise comparativa da qualidade posicional mapeamento urbano com VANT. in: congresso brasileiro de cadastro técnico multifinalitário e gestão territorial**, 13., 2018, Florianópolis. **Anais...** Florianópolis: Anais do Cobrac, 2018. p. 1 - 18.

TRIMBLE. **eCognition Developer 8.7 User Guide.** Munich, Germany: [s.n.], 2011. 258p. Disp. em: <<http://www.ecognition.com/>>.

TSCHIEDEL, A.F. et al. Construção de um modelo digital de superfície de uma voçoroca a partir do uso de drone. In: Encontro Nacional de Engenharia de Sedimentos. **Anais...** Vitória: ENES, 2018. p.1-8.

VENTURIERI, A.; SANTOS, J.R. **Técnicas de classificação de imagens para análise de cobertura vegetal**. In: EMBRAPA. Embrapa Amazônia Oriental. PlanaltinaDf: Embrapa, 1998. p. 351-371.

WANG, T.; HE, F.; ZHANG, A.; GU, L.; WEN, Y.; JIANG, W.; SHAO, H.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**, v. 2014, p. 1-11, 2014.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining: practical machine learning tools and techniques**. São FranciscoThe Morgan Kaufmann series in data management systems, 2011. 665 p.

ZAIDAN, R.T. Geoprocessamento Conceitos e Definições. **Revista de Geografia**, Juiz de Fora, v.7, n.2. p.195-201, 2017.

ZUQUETTE, L. V.; CARVALHO, J. A. R.; YAMANOUTH, G. R. D. B. Feições erosivas na bacia do córrego do Espirado, São Pedro (SP), seus tipos e evolução entre 1972 - 2002. **Revista Brasileira de Geociências**, Curitiba, v. 37, p. 414-425, junho 2007.

APÊNDICE 1 – Árvores de Decisão

1) Árvores de decisão - Área de Estudo 01

a) Árvore de Decisão – Dados Brutos

Decision Tree

Mean of outer border B \leq 126

| Mean of outer border G \leq 133.294118

| | Circular Mean R (R1 Length 3 R2 Same (= R1) border) \leq 117.517857

| | | Ratio G \leq 0.030586: Vocoroca (47.0/1.0)

| | | Ratio G $>$ 0.030586: Vegetacao Arborea (124.0/1.0)

| | Circular Mean R (R1 Length 3 R2 Same (= R1) border) $>$ 117.517857

| | | Max. pixel value MDE \leq 871.617188

| | | | Min. pixel value MDT \leq 864.103577: Solo Exposto (5.0)

| | | | Min. pixel value MDT $>$ 864.103577: Telhado Amianto (12.0)

| | | Max. pixel value MDE $>$ 871.617188

| | | | Mean of outer border G \leq 125.928571: Vocoroca (352.0)

| | | | Mean of outer border G $>$ 125.928571

| | | | | Border length \leq 70: Vocoroca (5.0)

| | | | | Border length $>$ 70: Vegetacao Arborea (3.0/1.0)

| Mean of outer border G $>$ 133.294118

| | GLCM Contrast (quick 8/11) (all dir.) \leq 33.578407

| | | Circular Mean G (R1 Length 3 R2 Same (= R1) border) \leq 136.764706: Solo Exposto (2.0/1.0)

| | | Circular Mean G (R1 Length 3 R2 Same (= R1) border) $>$ 136.764706: Vegetacao Rasteira (69.0)

| | GLCM Contrast (quick 8/11) (all dir.) $>$ 33.578407: Vegetacao Arborea (36.0/1.0)

Mean of outer border B $>$ 126

| GLCM Contrast (quick 8/11) (all dir.) \leq 1.820232

| | Min. pixel value MDT \leq 866.942261: Asfalto (53.0/1.0)

| | Min. pixel value MDT $>$ 866.942261: Telhado Fibrocimento/Metalica (13.0/1.0)

| GLCM Contrast (quick 8/11) (all dir.) $>$ 1.820232

| | Ratio R \leq 0.059839

| | | Min. pixel value B \leq 125

| | | Ratio G \leq 0.042409: Vocoroca (3.0/1.0)

| | | | Ratio G > 0.042409: Vegetacao Rasteira (5.0)

| | | Min. pixel value B > 125

| | | | Min. pixel value MDT <= 902.100464: Telhado Fibrocimento/Metalica (75.0/1.0)

| | | | Min. pixel value MDT > 902.100464: Asfalto (6.0)

| | Ratio R > 0.059839

| | | Ratio B <= 0.061504

| | | | Min. pixel value MDT <= 887.237732

| | | | | Max. pixel value MDT <= 866.579102: Solo Exposto (22.0/1.0)

| | | | | Max. pixel value MDT > 866.579102

| | | | | | Mean of outer border G <= 188.901639

| | | | | | | Mean of outer border R <= 188.5: Solo Exposto (3.0/1.0)

| | | | | | | Mean of outer border R > 188.5

| | | | | | | | Min. pixel value G <= 147: Telhado Amianto (60.0)

| | | | | | | | Min. pixel value G > 147

| | | | | | | | | Max. pixel value R <= 242: Solo Exposto (6.0)

| | | | | | | | | Max. pixel value R > 242: Telhado Amianto (10.0)

| | | | | | | | | Mean of outer border G > 188.901639: Solo Exposto (6.0)

| | | | | Min. pixel value MDT > 887.237732

| | | | | GLCM Contrast (quick 8/11) (all dir.) <= 26.193111: Solo Exposto (50.0)

| | | | | GLCM Contrast (quick 8/11) (all dir.) > 26.193111: Vocoroca (3.0)

| | | Ratio B > 0.061504

| | | | Min. pixel value R <= 212: Telhado Fibrocimento/Metalica (11.0)

| | | | Min. pixel value R > 212: Telhado Amianto (2.0)

Number of Leaves : 26

Size of the tree : 51

=== **Stratified cross-validation** ===

=== **Summary** ===

Correctly Classified Instances	923	93.8962 %
Incorrectly Classified Instances	60	6.1038 %
Kappa statistic	0.92	
Mean absolute error	0.0189	
Root mean squared error	0.1283	
Relative absolute error	8.6584 %	

Root relative squared error 38.8706 %

Total Number of Instances 983

=== **Confusion Matrix** ===

```

a b c d e f g <-- classified as
72 1 1 0 0 0 0 | a = Vegetacao Rasteira
1 398 0 1 3 2 6 | b = Vocoroca
0 0 57 3 1 0 0 | c = Asfalto
0 0 1 93 2 1 0 | d = Telhado Fibrocimento/Metalica
1 2 4 2 74 9 0 | e = Solo Exposto
0 3 0 2 3 78 0 | f = Telhado Amianto
5 6 0 0 0 0 151 | g = Vegetacao Arborea

```

b) **Árvore de Decisão – CAE**

Decision tree

Mean of outer border B <= 126

| Mean of outer border G <= 133.294118

| | Circular Mean R (R1 Length 3 R2 Same (= R1) border) <= 117.517857

| | | Ratio G <= 0.030586: Vocoroca (47.0/1.0)

| | | Ratio G > 0.030586: Vegetacao Arborea (124.0/1.0)

| | Circular Mean R (R1 Length 3 R2 Same (= R1) border) > 117.517857

| | | Max. pixel value MDT <= 871.281555

| | | | Min. pixel value MDT <= 864.103577: Solo Exposto (5.0)

| | | | Min. pixel value MDT > 864.103577: Telhado Amianto (12.0)

| | | Max. pixel value MDT > 871.281555

| | | | Mean of outer border G <= 125.928571: Vocoroca (352.0)

| | | | Mean of outer border G > 125.928571

| | | | | Border length <= 70: Vocoroca (5.0)

| | | | | Border length > 70: Vegetacao Arborea (3.0/1.0)

| Mean of outer border G > 133.294118

| | GLCM Homogeneity (quick 8/11) (all dir.) <= 0.178251: Vegetacao Arborea (34.0/1.0)

| | GLCM Homogeneity (quick 8/11) (all dir.) > 0.178251

| | | Circular Mean B (R1 Length 3 R2 Same (= R1) border) <= 75.045455: Vegetacao Arborea (3.0)

| | | Circular Mean B (R1 Length 3 R2 Same (= R1) border) > 75.045455: Vegetacao Rasteira (70.0/1.0)

Mean of outer border B > 126

| GLCM Homogeneity (quick 8/11) (all dir.) <= 0.555556

| | Ratio R <= 0.059839

| | | Min. pixel value B <= 125

| | | | Ratio G <= 0.042409: Vocoroca (3.0/1.0)

| | | | Ratio G > 0.042409: Vegetacao Rasteira (5.0)

| | | Min. pixel value B > 125

| | | | Min. pixel value MDT <= 902.100464

| | | | | Min. pixel value MDT <= 865.9552: Asfalto (2.0)

| | | | | Min. pixel value MDT > 865.9552: Telhado Fibrocimento/Metalica (74.0)

| | | | Min. pixel value MDT > 902.100464: Asfalto (6.0)

| | Ratio R > 0.059839

| | | Mean of outer border B <= 196.201613

| | | | Min. pixel value MDT <= 887.237732

| | | | | Max. pixel value MDT <= 866.579102

| | | | | | Mean of outer border R <= 197.784314: Asfalto (3.0/1.0)

| | | | | | Mean of outer border R > 197.784314: Solo Exposto (21.0)

| | | | | Max. pixel value MDT > 866.579102

| | | | | | Mean of outer border G <= 188.901639

| | | | | | | Mean of outer border R <= 188.5: Solo Exposto (3.0/1.0)

| | | | | | | Mean of outer border R > 188.5

| | | | | | | | Min. pixel value G <= 147: Telhado Amianto (60.0)

| | | | | | | | Min. pixel value G > 147

| | | | | | | | Ratio R <= 0.071778: Solo Exposto (6.0)

| | | | | | | | Ratio R > 0.071778: Telhado Amianto (10.0)

| | | | | | | | Mean of outer border G > 188.901639: Solo Exposto (6.0)

| | | | | Min. pixel value MDT > 887.237732

| | | | | GLCM Homogeneity (quick 8/11) (all dir.) <= 0.23209: Vocoroca (4.0/1.0)

| | | | | GLCM Homogeneity (quick 8/11) (all dir.) > 0.23209: Solo Exposto (49.0)

| | | Mean of outer border B > 196.201613

| | | | Ratio R <= 0.071695: Telhado Fibrocimento/Metalica (7.0)

| | | Ratio R > 0.071695: Telhado Amianto (2.0)
 | GLCM Homogeneity (quick 8/11) (all dir.) > 0.555556
 | | Min. pixel value MDT <= 866.942261: Asfalto (50.0)
 | | Min. pixel value MDT > 866.942261: Telhado Fibrocimento/Metalica (17.0/1.0)

Number of Leaves : 28

Size of the tree : 55

=== **Stratified cross-validation** ===

=== **Summary** ===

Correctly Classified Instances	921	93.6928 %
Incorrectly Classified Instances	62	6.3072 %
Kappa statistic	0.9173	
Mean absolute error	0.0193	
Root mean squared error	0.1293	
Relative absolute error	8.8334 %	
Root relative squared error	39.1799 %	
Total Number of Instances	983	

=== **Confusion Matrix** ===

```

a b c d e f g <-- classified as
68 1 1 0 0 0 4 | a = Vegetacao Rasteira
2399 0 1 4 0 5 | b = Vocoroca
1 0 55 4 1 0 0 | c = Asfalto
0 0 1 92 4 0 0 | d = Telhado Fibrocimento/Metalica
2 2 3 1 75 9 0 | e = Solo Exposto
1 2 1 0 4 78 0 | f = Telhado Amianto
3 5 0 0 0 0 154 | g = Vegetacao Arborea

```

c) **Árvore de decisão – PCA**

Decision Tree

A <= -21.356837

| B <= 1031.37

| | A <= -30.953452

| | | F <= 34.31

| | | | E <= -4.48: Solo Exposto (2.0)

| | | | E > -4.48: Asfalto (5.0)

| | | F > 34.31: Asfalto (45.0)

| | A > -30.953452

| | | B <= 1030.68: Solo Exposto (21.0/1.0)

| | | B > 1030.68: Telhado Fibrocimento/Metalica (2.0)

| B > 1031.37

| | B <= 1072.02

| | | A <= -25.686561

| | | | I <= 74.03

| | | | | A <= -33.143382

| | | | | | A <= -33.684022: Telhado Fibrocimento/Metalica (3.0)

| | | | | | A > -33.684022: Asfalto (2.0)

| | | | | | A > -33.143382: Telhado Fibrocimento/Metalica (54.0)

| | | | | I > 74.03

| | | | | | D <= -37.97

| | | | | | | A <= -30.596298: Telhado Fibrocimento/Metalica (24.0/1.0)

| | | | | | | A > -30.596298

| | | | | | | | C <= 1493.91: Solo Exposto (3.0)

| | | | | | | | C > 1493.91: Telhado Fibrocimento/Metalica (2.0)

| | | | | | | D > -37.97

| | | | | | | | G <= 0.3

| | | | | | | | | I <= 74.85: Telhado Fibrocimento/Metalica (2.0/1.0)

| | | | | | | | | I > 74.85

| | | | | | | | | | B <= 1033.69

| | | | | | | | | | | G <= 0.06: Telhado Amianto (3.0)

| | | | | | | | | | | G > 0.06: Solo Exposto (3.0)

| | | | | | | | | | | B > 1033.69: Solo Exposto (8.0)

| | | | | | | | | | | G > 0.3

| | | | | | | | | | | | H <= -275.23: Telhado Fibrocimento/Metalica (4.0)

| | | | | | | | | | | | H > -275.23: Telhado Amianto (11.0)

| | | | | | | | | | | | A > -25.686561

| | | | | | | | | | | | | I <= 65.01: Telhado Fibrocimento/Metalica (9.0/1.0)

| | | | I > 65.01
 | | | | | B <= 1056.27
 | | | | | | I <= 69.64
 | | | | | | | I <= 66.99: Telhado Amianto (4.0)
 | | | | | | | I > 66.99: Solo Exposto (2.0)
 | | | | | | I > 69.64: Telhado Amianto (29.0)
 | | | | | B > 1056.27: Solo Exposto (4.0)
 | | B > 1072.02
 | | | C <= 1513.07
 | | | | E <= -16.46
 | | | | | A <= -23.340721: Vocoroca (2.0)
 | | | | | A > -23.340721: Vegetacao Rasteira (2.0/1.0)
 | | | | | E > -16.46
 | | | | | I <= 70.94: Asfalto (6.0/1.0)
 | | | | | I > 70.94
 | | | | | | H <= -661.15: Asfalto (2.0)
 | | | | | | H > -661.15: Solo Exposto (40.0)
 | | | C > 1513.07: Vocoroca (2.0/1.0)
 A > -21.356837
 | B <= 1040.09
 | | A <= -15.349806
 | | | B <= 1028.67: Solo Exposto (6.0)
 | | | B > 1028.67: Telhado Amianto (33.0/2.0)
 | | A > -15.349806
 | | | M <= -19.47: Vegetacao Arborea (66.0/2.0)
 | | | M > -19.47
 | | | | I <= 37.91: Vegetacao Arborea (7.0/1.0)
 | | | | I > 37.91: Vocoroca (5.0)
 | B > 1040.09
 | | D <= -8.81
 | | | A <= -13.165406
 | | | | M <= -27.29
 | | | | | E <= -19.22

| | | | | B <= 1056.92: Telhado Amianto (4.0/1.0)
 | | | | | B > 1056.92
 | | | | | B <= 1096.42: Vocoroca (10.0)
 | | | | | B > 1096.42: Vegetacao Rasteira (3.0/1.0)
 | | | | | E > -19.22
 | | | | | C <= 1511.22: Vegetacao Rasteira (64.0/2.0)
 | | | | | C > 1511.22: Vocoroca (2.0)
 | | | | M > -27.29: Vocoroca (63.0/3.0)
 | | | A > -13.165406
 | | | | C <= 1583.82
 | | | | | E <= -21.02
 | | | | | D <= -7210.71
 | | | | | B <= 1050.48: Vegetacao Arborea (2.0)
 | | | | | B > 1050.48
 | | | | | B <= 1107: Vocoroca (30.0)
 | | | | | B > 1107: Vegetacao Arborea (2.0)
 | | | | | D > -7210.71: Vocoroca (196.0/1.0)
 | | | | | E > -21.02
 | | | | | F <= 57.24
 | | | | | M <= -22.04
 | | | | | I <= 53.72
 | | | | | H <= -252.18
 | | | | | E <= -14.63: Vocoroca (6.0)
 | | | | | E > -14.63: Vegetacao Arborea (3.0/1.0)
 | | | | | H > -252.18: Vegetacao Arborea (11.0/1.0)
 | | | | | I > 53.72
 | | | | | I <= 60.25: Vegetacao Rasteira (4.0/1.0)
 | | | | | I > 60.25: Vocoroca (9.0/1.0)
 | | | | | M > -22.04
 | | | | | J <= 137.69: Vocoroca (45.0)
 | | | | | J > 137.69
 | | | | | B <= 1050.48: Vegetacao Arborea (4.0)
 | | | | | B > 1050.48: Vocoroca (6.0)

```

| | | | | F > 57.24: Vegetacao Rasteira (4.0)
| | | | C > 1583.82: Vegetacao Arborea (7.0)
| | D > -8.81
| | | J <= 134.86
| | | | E <= -13.19
| | | | | G <= 0.1
| | | | | D <= -4.72: Vegetacao Arborea (2.0)
| | | | | D > -4.72: Vocoroca (13.0)
| | | | | G > 0.1
| | | | | | G <= 1.53
| | | | | | | I <= 60.13: Vegetacao Arborea (14.0)
| | | | | | | I > 60.13: Vocoroca (3.0/1.0)
| | | | | | | G > 1.53
| | | | | | | A <= -10.252498: Vocoroca (4.0)
| | | | | | | A > -10.252498: Vegetacao Arborea (3.0/1.0)
| | | | E > -13.19: Vocoroca (10.0/1.0)
| | | J > 134.86
| | | | E <= -14.63: Vegetacao Arborea (43.0/1.0)
| | | | E > -14.63: Vocoroca (3.0/1.0)

```

Number of Leaves : 62

Size of the tree : 123

=== **Stratified cross-validation** ===

=== **Summary** ===

Correctly Classified Instances	841	85.5544 %
Incorrectly Classified Instances	142	14.4456 %
Kappa statistic	0.8105	
Mean absolute error	0.046	
Root mean squared error	0.1959	
Relative absolute error	21.1011 %	
Root relative squared error	59.3634 %	
Total Number of Instances	983	

=== **Confusion Matrix** ===

a b c d e f g <-- classified as

64 8 0 0 0 1 1 | a = Vegetacao Rasteira

11 363 1 1 1 1 33 | b = Vocoroca

0 0 54 2 5 0 0 | c = Asfalto

0 0 1 88 6 2 0 | d = Telhado Fibrocimento/Metalica

2 2 5 4 73 5 1 | e = Solo Exposto

0 4 0 4 7 70 1 | f = Telhado Amianto

0 33 0 0 0 0 129 | g = Vegetacao Arborea

d) **Árvore de Decisão – InfoGain**

Decision Tree

Mean of outer border B <= 126

| Mean of outer border G <= 133.294118

| | Circular Mean B (R1 Length 3 R2 Same (= R1) border) <= 86.073529

| | | Mean of outer border G <= 94.785714

| | | | Mean of outer border G <= 81.363636: Vocoroca (83.0)

| | | | Mean of outer border G > 81.363636

| | | | | Circular Mean B (R1 Length 3 R2 Same (= R1) border) <= 63.553571: Vegetacao Arborea (9.0)

| | | | | Circular Mean B (R1 Length 3 R2 Same (= R1) border) > 63.553571

| | | | | | Mean of outer border B <= 63.083333: Vegetacao Arborea (3.0/1.0)

| | | | | | Mean of outer border B > 63.083333: Vocoroca (19.0)

| | | | | Mean of outer border G > 94.785714: Vegetacao Arborea (116.0/4.0)

| | | | | Circular Mean B (R1 Length 3 R2 Same (= R1) border) > 86.073529

| | | | | Mean of outer border B <= 109.368421: Vocoroca (259.0/3.0)

| | | | | Mean of outer border B > 109.368421

| | | | | | Mean of outer border G <= 104.657895: Telhado Amianto (5.0)

| | | | | | Mean of outer border G > 104.657895

| | | | | | Mean of outer border B <= 116.0625

| | | | | | Mean of outer border G <= 122.702128: Vocoroca (19.0)

| | | | | | Mean of outer border G > 122.702128

| | | | | | | Ratio MDT <= 0.289514: Solo Exposto (4.0)

| | | | | | | Ratio MDT > 0.289514: Vocoroca (3.0/1.0)

| | | | | | | Mean of outer border B > 116.0625

| | | | | | | Ratio MDT <= 0.292425

| | | | | | Circular Mean B (R1 Length 3 R2 Same (= R1) border) <= 119.5625

| | | | | | Mean of inner border B <= 110.234043: Telhado Amianto (3.0/1.0)

| | | | | | Mean of inner border B > 110.234043: Vocoroca (10.0)

| | | | | | Circular Mean B (R1 Length 3 R2 Same (= R1) border) > 119.5625: Telhado Amianto (6.0)

| | | | | | Ratio MDT > 0.292425: Vocoroca (9.0)

| Mean of outer border G > 133.294118

| | Mean of outer border B <= 82.95122: Vegetacao Arborea (30.0)

| | Mean of outer border B > 82.95122

| | | Max. diff. <= 1.494734

| | | | Mean of outer border B <= 117.579545: Vegetacao Arborea (4.0)

| | | | Mean of outer border B > 117.579545: Vegetacao Rasteira (4.0/1.0)

| | | Max. diff. > 1.494734: Vegetacao Rasteira (69.0/3.0)

Mean of outer border B > 126

| Ratio B <= 0.058016

| | Min. pixel value B <= 125

| | | Ratio MDT <= 0.291794

| | | | Min. pixel value B <= 113: Telhado Amianto (21.0)

| | | | Min. pixel value B > 113

| | | | | Ratio MDT <= 0.282839: Telhado Amianto (14.0/2.0)

| | | | | Ratio MDT > 0.282839

| | | | | Mean of outer border G <= 137.727273: Telhado Amianto (3.0/1.0)

| | | | | Mean of outer border G > 137.727273: Solo Exposto (12.0/1.0)

| | | Ratio MDT > 0.291794

| | | | Ratio B <= 0.037338: Vocoroca (2.0)

| | | | Ratio B > 0.037338: Vegetacao Rasteira (5.0)

| | Min. pixel value B > 125

| | | Ratio MDT <= 0.28119

| | | | Mean of outer border G <= 159.369048

| | | | | Max. pixel value B <= 166

| | | | | Mean of outer border G <= 144.304348: Telhado Amianto (4.0)

| | | | | Mean of outer border G > 144.304348

| | | | | | Mean of outer border B <= 146.277143: Solo Exposto (4.0)

| | | | | | Mean of outer border B > 146.277143: Telhado Amianto (3.0/1.0)

| | | | | Max. pixel value B > 166: Telhado Amianto (16.0/1.0)

| | | | Mean of outer border G > 159.369048

| | | | | Ratio MDT <= 0.270357: Telhado Amianto (3.0)

| | | | | Ratio MDT > 0.270357

| | | | | | Mean B <= 174.052239

| | | | | | | Circular Mean B (R1 Length 3 R2 Same (= R1) border) <= 160.853659: Solo Exposto (15.0/1.0)

| | | | | | | Circular Mean B (R1 Length 3 R2 Same (= R1) border) > 160.853659

| | | | | | | | Max. pixel value B <= 185

| | | | | | | | Ratio B <= 0.051407: Telhado Amianto (3.0)

| | | | | | | | Ratio B > 0.051407

| | | | | | | | | Min. pixel value B <= 157: Solo Exposto (5.0)

| | | | | | | | | Min. pixel value B > 157: Telhado Amianto (3.0/1.0)

| | | | | | | | | Max. pixel value B > 185: Telhado Amianto (4.0)

| | | | | | Mean B > 174.052239: Solo Exposto (20.0/1.0)

| | | Ratio MDT > 0.28119

| | | | Ratio B <= 0.0497

| | | | | Ratio MDT <= 0.286402: Solo Exposto (24.0/2.0)

| | | | | Ratio MDT > 0.286402: Telhado Fibrocimento/Metalica (6.0)

| | | | Ratio B > 0.0497

| | | | | Max. diff. <= 1.387371: Solo Exposto (2.0)

| | | | | Max. diff. > 1.387371: Telhado Fibrocimento/Metalica (34.0)

| Ratio B > 0.058016

| | Max. pixel value B <= 217

| | | Ratio MDT <= 0.277627

| | | | Mean of outer border G <= 187.341772

| | | | | Ratio MDT <= 0.277034: Asfalto (51.0/3.0)

| | | | | Ratio MDT > 0.277034

| | | | | | Ratio MDT <= 0.27728: Telhado Fibrocimento/Metalica (2.0)

| | | | | | Ratio MDT > 0.27728: Asfalto (2.0)

| | | | Mean of outer border G > 187.341772

| | | | | Ratio B <= 0.061504: Solo Exposto (5.0)

```

| | | | | Ratio B > 0.061504: Telhado Fibrocimento/Metalica (3.0/1.0)
| | | Ratio MDT > 0.277627
| | | | Ratio MDT <= 0.282564
| | | | | Ratio MDT <= 0.277954
| | | | | | Ratio MDT <= 0.277718: Telhado Fibrocimento/Metalica (2.0)
| | | | | | Ratio MDT > 0.277718: Asfalto (2.0)
| | | | | Ratio MDT > 0.277954: Telhado Fibrocimento/Metalica (25.0)
| | | | Ratio MDT > 0.282564: Asfalto (7.0)
| | Max. pixel value B > 217: Telhado Fibrocimento/Metalica (26.0/2.0)

```

Number of Leaves : 49

Size of the tree : 97

=== **Stratified cross-validation** ===

=== **Summary** ===

Correctly Classified Instances	862	87.6907 %
Incorrectly Classified Instances	121	12.3093 %
Kappa statistic	0.8385	
Mean absolute error	0.0414	
Root mean squared error	0.179	
Relative absolute error	18.9846 %	
Root relative squared error	54.2501 %	
Total Number of Instances	983	

=== **Confusion Matrix** ===

```

a b c d e f g <-- classified as
66 3 0 1 0 0 4 | a = Vegetacao Rasteira
3 390 1 0 2 7 8 | b = Vocoroca
0 0 54 5 2 0 0 | c = Asfalto
0 0 5 88 3 1 0 | d = Telhado Fibrocimento/Metalica
1 3 3 5 61 19 0 | e = Solo Exposto
0 7 0 3 20 56 0 | f = Telhado Amianto
5 10 0 0 0 0 147 | g = Vegetacao Arborea

```

2) Árvores de Decisão – Área de Estudo 02

a) Árvore de Decisão – Dados Brutos

Decision tree

Ratio G \leq 0.312732

| Ratio R \leq 0.346496: Rodovia (36.0/1.0)

| Ratio R $>$ 0.346496

| | Max. diff. \leq 0.250379

| | | Min. pixel value R \leq 182

| | | | Max. pixel value MDT \leq 887.775635: Voco-roca (2.0)

| | | | Max. pixel value MDT $>$ 887.775635: Vegetacao presente na Voco-roca (49.0)

| | | Min. pixel value R $>$ 182

| | | | Min. pixel value MDT \leq 898.983398: Solo Exposto (35.0)

| | | | Min. pixel value MDT $>$ 898.983398: Vegetacao presente na Voco-roca (3.0/1.0)

| | Max. diff. $>$ 0.250379

| | | Min. pixel value MDT \leq 888.038757

| | | | Min. pixel value G \leq 130: Voco-roca (3.0)

| | | | Min. pixel value G $>$ 130: Solo Exposto (3.0)

| | | Min. pixel value MDT $>$ 888.038757: Voco-roca (52.0)

Ratio G $>$ 0.312732

| Ratio B \leq 0.305755: Vegetação Arbórea (42.0)

| Ratio B $>$ 0.305755

| | Max. pixel value R \leq 227: Vegetação Rasteira (43.0)

| | Max. pixel value R $>$ 227

| | | Border length \leq 106: Solo Exposto (2.0)

| | | Border length $>$ 106: Rodovia (2.0/1.0)

Number of Leaves : 12

Size of the tree : 23

=== **Stratified cross-validation** ===

=== **Summary** ===

Correctly Classified Instances 248 91.1765 %

Incorrectly Classified Instances 24 8.8235 %

Kappa statistic 0.8936

Mean absolute error 0.0284

Root mean squared error 0.1546

Relative absolute error 10.2935 %

Root relative squared error 41.5996 %
 Total Number of Instances 272

=== **Confusion Matrix** ===

a b c d e f <-- classified as
 41 0 0 0 2 0 | a = Vegetação Rasteira
 0 34 0 0 0 2 | b = Rodovia
 1 0 41 0 0 0 | c = Vegetação Arbórea
 0 1 0 52 4 1 | d = Vocoroca
 3 0 0 2 46 1 | e = Vegetacao presente na Vocoroca
 0 3 0 3 1 34 | f = Solo Exposto

b) **Árvore de decisão CAE**

Decision Tree

Ratio G <= 0.312732

| Ratio R <= 0.346496: Rodovia (36.0/1.0)

| Ratio R > 0.346496

| | Max. diff. <= 0.250379

| | | Mean of outer border R <= 190.674419

| | | | Min. pixel value MDE <= 887.854309: Vocoroca (2.0)

| | | | Min. pixel value MDE > 887.854309: Vegetacao presente na Vocoroca (49.0)

| | | Mean of outer border R > 190.674419

| | | | Min. pixel value MDE <= 898.983398: Solo Exposto (35.0)

| | | | Min. pixel value MDE > 898.983398: Vegetacao presente na Vocoroca (3.0/1.0)

| | Max. diff. > 0.250379

| | | Min. pixel value MDE <= 888.038757

| | | | Mean of inner border G <= 143.30303: Vocoroca (3.0)

| | | | Mean of inner border G > 143.30303: Solo Exposto (3.0)

| | | Min. pixel value MDE > 888.038757: Vocoroca (52.0)

Ratio G > 0.312732

| Ratio B <= 0.305755: Vegetação Arbórea (42.0)

| Ratio B > 0.305755

| | Mean of inner border $G \leq 201.877551$: Vegetação Rasteira (44.0/1.0)

| | Mean of inner border $G > 201.877551$: Solo Exposto (3.0/1.0)

Number of Leaves : 11

Size of the tree : 21

=== **Stratified cross-validation** ===

=== **Summary** ===

Correctly Classified Instances 248 91.1765 %

Incorrectly Classified Instances 24 8.8235 %

Kappa statistic 0.8934

Mean absolute error 0.03

Root mean squared error 0.159

Relative absolute error 10.8495 %

Root relative squared error 42.7831 %

Total Number of Instances 272

=== **Confusion Matrix** ===

a b c d e f <-- classified as

41 0 0 0 2 0 | a = Vegetação Rasteira

0 32 0 1 0 3 | b = Rodovia

0 0 42 0 0 0 | c = Vegetação Arbórea

0 0 0 52 5 1 | d = Vocoroca

2 0 0 3 47 0 | e = Vegetacao presente na Vocoroca

1 2 0 3 1 34 | f = Solo Exposto

c) Árvores de decisão – PCA

Decision Tree

A ≤ -21.356837

| B ≤ 1031.37

| | A ≤ -30.953452

| | | F ≤ 34.31

| | | | E ≤ -4.48 : Solo Exposto (2.0)

| | | | E > -4.48 : Asfalto (5.0)

| | | F > 34.31 : Asfalto (45.0)

| | A > -30.953452

| | | B <= 1030.68: Solo Exposto (21.0/1.0)

| | | B > 1030.68: Telhado Fibrocimento/Metalica (2.0)

| B > 1031.37

| | B <= 1072.02

| | | A <= -25.686561

| | | | I <= 74.03

| | | | | A <= -33.143382

| | | | | | A <= -33.684022: Telhado Fibrocimento/Metalica (3.0)

| | | | | | A > -33.684022: Asfalto (2.0)

| | | | | | A > -33.143382: Telhado Fibrocimento/Metalica (54.0)

| | | | | I > 74.03

| | | | | | D <= -37.97

| | | | | | | A <= -30.596298: Telhado Fibrocimento/Metalica (24.0/1.0)

| | | | | | | A > -30.596298

| | | | | | | | C <= 1493.91: Solo Exposto (3.0)

| | | | | | | | C > 1493.91: Telhado Fibrocimento/Metalica (2.0)

| | | | | | | D > -37.97

| | | | | | | | G <= 0.3

| | | | | | | | | I <= 74.85: Telhado Fibrocimento/Metalica (2.0/1.0)

| | | | | | | | | I > 74.85

| | | | | | | | | B <= 1033.69

| | | | | | | | | | G <= 0.06: Telhado Amianto (3.0)

| | | | | | | | | | G > 0.06: Solo Exposto (3.0)

| | | | | | | | | | B > 1033.69: Solo Exposto (8.0)

| | | | | | | | | | G > 0.3

| | | | | | | | | | | H <= -275.23: Telhado Fibrocimento/Metalica (4.0)

| | | | | | | | | | | H > -275.23: Telhado Amianto (11.0)

| | | | A > -25.686561

| | | | | I <= 65.01: Telhado Fibrocimento/Metalica (9.0/1.0)

| | | | | I > 65.01

| | | | | | B <= 1056.27

| | | | | | | I <= 69.64

| | | | | I <= 66.99: Telhado Amianto (4.0)

| | | | | I > 66.99: Solo Exposto (2.0)

| | | | | I > 69.64: Telhado Amianto (29.0)

| | | | | B > 1056.27: Solo Exposto (4.0)

| | B > 1072.02

| | | C <= 1513.07

| | | | E <= -16.46

| | | | | A <= -23.340721: Vocoroca (2.0)

| | | | | A > -23.340721: Vegetacao Rasteira (2.0/1.0)

| | | | | E > -16.46

| | | | | I <= 70.94: Asfalto (6.0/1.0)

| | | | | I > 70.94

| | | | | | H <= -661.15: Asfalto (2.0)

| | | | | | H > -661.15: Solo Exposto (40.0)

| | | C > 1513.07: Vocoroca (2.0/1.0)

A > -21.356837

| B <= 1040.09

| | A <= -15.349806

| | | B <= 1028.67: Solo Exposto (6.0)

| | | B > 1028.67: Telhado Amianto (33.0/2.0)

| | A > -15.349806

| | | M <= -19.47: Vegetacao Arborea (66.0/2.0)

| | | M > -19.47

| | | | I <= 37.91: Vegetacao Arborea (7.0/1.0)

| | | | I > 37.91: Vocoroca (5.0)

| B > 1040.09

| | D <= -8.81

| | | A <= -13.165406

| | | | M <= -27.29

| | | | | E <= -19.22

| | | | | | B <= 1056.92: Telhado Amianto (4.0/1.0)

| | | | | | B > 1056.92

| | | | | | | B <= 1096.42: Vocoroca (10.0)

| | | | | B > 1096.42: Vegetacao Rasteira (3.0/1.0)
 | | | | | E > -19.22
 | | | | | C <= 1511.22: Vegetacao Rasteira (64.0/2.0)
 | | | | | C > 1511.22: Vocoroca (2.0)
 | | | | M > -27.29: Vocoroca (63.0/3.0)
 | | | A > -13.165406
 | | | | C <= 1583.82
 | | | | | E <= -21.02
 | | | | | D <= -7210.71
 | | | | | B <= 1050.48: Vegetacao Arborea (2.0)
 | | | | | B > 1050.48
 | | | | | B <= 1107: Vocoroca (30.0)
 | | | | | B > 1107: Vegetacao Arborea (2.0)
 | | | | | D > -7210.71: Vocoroca (196.0/1.0)
 | | | | | E > -21.02
 | | | | | F <= 57.24
 | | | | | M <= -22.04
 | | | | | I <= 53.72
 | | | | | H <= -252.18
 | | | | | E <= -14.63: Vocoroca (6.0)
 | | | | | E > -14.63: Vegetacao Arborea (3.0/1.0)
 | | | | | H > -252.18: Vegetacao Arborea (11.0/1.0)
 | | | | | I > 53.72
 | | | | | I <= 60.25: Vegetacao Rasteira (4.0/1.0)
 | | | | | I > 60.25: Vocoroca (9.0/1.0)
 | | | | | M > -22.04
 | | | | | J <= 137.69: Vocoroca (45.0)
 | | | | | J > 137.69
 | | | | | B <= 1050.48: Vegetacao Arborea (4.0)
 | | | | | B > 1050.48: Vocoroca (6.0)
 | | | | | F > 57.24: Vegetacao Rasteira (4.0)
 | | | | C > 1583.82: Vegetacao Arborea (7.0)
 | | D > -8.81

```

| | | J <= 134.86
| | | | E <= -13.19
| | | | | G <= 0.1
| | | | | | D <= -4.72: Vegetacao Arborea (2.0)
| | | | | | D > -4.72: Vocoroca (13.0)
| | | | | | G > 0.1
| | | | | | G <= 1.53
| | | | | | | I <= 60.13: Vegetacao Arborea (14.0)
| | | | | | | I > 60.13: Vocoroca (3.0/1.0)
| | | | | | | G > 1.53
| | | | | | | A <= -10.252498: Vocoroca (4.0)
| | | | | | | A > -10.252498: Vegetacao Arborea (3.0/1.0)
| | | | E > -13.19: Vocoroca (10.0/1.0)
| | | J > 134.86
| | | | E <= -14.63: Vegetacao Arborea (43.0/1.0)
| | | | E > -14.63: Vocoroca (3.0/1.0)

```

Number of Leaves : 62

Size of the tree : 123

=== **Stratified cross-validation** ===

=== **Summary** ===

Correctly Classified Instances	841	85.5544 %
Incorrectly Classified Instances	142	14.4456 %
Kappa statistic	0.8105	
Mean absolute error	0.046	
Root mean squared error	0.1959	
Relative absolute error	21.1011 %	
Root relative squared error	59.3634 %	
Total Number of Instances	983	

=== **Confusion Matrix** ===

a b c d e f g <-- classified as

64 8 0 0 0 1 1 | a = Vegetacao Rasteira

11 363 1 1 1 1 33 | b = Vocoroca

0 0 54 2 5 0 0 | c = Asfalto

0 0 1 88 6 2 0 | d = Telhado Fibrocimento/Metalica
 2 2 5 4 73 5 1 | e = Solo Exposto
 0 4 0 4 7 70 1 | f = Telhado Amianto
 0 33 0 0 0 0 129 | g = Vegetacao Arborea

d) Árvore de Decisão – InfoGain

Decision Tree

```

Ratio G <= 0.312732
| Ratio R <= 0.346496: Rodovia (36.0/1.0)
| Ratio R > 0.346496
| | Max. diff. <= 0.250379
| | | Mean B <= 180
| | | | Max. pixel value MDT <= 887.775635: Vocoroca (2.0)
| | | | Max. pixel value MDT > 887.775635: Vegetacao presente na Vocoroca
(46.0)
| | | | Mean B > 180
| | | | | Min. pixel value MDT <= 898.983398: Solo Exposto (36.0/1.0)
| | | | | Min. pixel value MDT > 898.983398: Vegetacao presente na Vocoroca
(5.0/1.0)
| | | | Max. diff. > 0.250379
| | | | | Min. pixel value MDT <= 888.038757
| | | | | | Min. pixel value B <= 149: Vocoroca (3.0)
| | | | | | Min. pixel value B > 149: Solo Exposto (3.0)
| | | | | Min. pixel value MDT > 888.038757: Vocoroca (52.0)
Ratio G > 0.312732
| Ratio B <= 0.305755: Vegetação Arbórea (42.0)
| Ratio B > 0.305755
| | Min. pixel value B <= 196: Vegetação Rasteira (44.0/1.0)
| | Min. pixel value B > 196: Solo Exposto (3.0/1.0)

```

Number of Leaves : 11

Size of the tree : 21

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	245	90.0735 %
Incorrectly Classified Instances	27	9.9265 %
Kappa statistic	0.8801	
Mean absolute error	0.0349	
Root mean squared error	0.1723	
Relative absolute error	12.6206 %	
Root relative squared error	46.3562 %	
Total Number of Instances	272	

=== Confusion Matrix ===

```

a b c d e f <-- classified as
41 0 0 0 2 0 | a = Vegetação Rasteira
0 33 0 0 0 3 | b = Rodovia
1 0 41 0 0 0 | c = Vegetação Arbórea

```

0 0 0 51 5 2 | d = Vocoroca
1 0 0 2 48 1 | e = Vegetacao presente na Vocoroca
1 2 0 4 3 31 | f = Solo Exposto