



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA E DE AGRIMENSURA
CURSO DE GRADUAÇÃO EM ENGENHARIA CARTOGRÁFICA E DE
AGRIMENSURA

SABRINA DE OLIVEIRA GOMES

**APLICAÇÃO DE GEOBIA PARA CLASSIFICAÇÃO DE ÁREA URBANA
UTILIZANDO IMAGENS ÓPTICAS DO PROJETO PE3D**

Recife
2020

SABRINA DE OLIVEIRA GOMES

**APLICAÇÃO DE GEOBIA PARA CLASSIFICAÇÃO DE ÁREA URBANA
UTILIZANDO IMAGENS ÓPTICAS DO PROJETO PE3D**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do Grau de Bacharel em Engenharia Cartográfica e Agrimensura.

Orientadora: Profa. Dra. Ana Lúcia Bezerra Candeias.

Coorientador: Prof. Dr. Anderson Reis Soares.

Recife

2020

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

G633a Gomes, Sabrina de Oliveira.
Aplicação de geobias para classificação de área urbana utilizando
imagens ópticas do projeto PE3D / Sabrina de Oliveira Gomes. -
2020.

65 folhas, il., gráfs., tabs.

Orientadora: Profa. Dra. Ana Lúcia Bezerra Candeias.

Coorientador: Prof. Dr. Anderson Reis Soares.

TCC (Graduação) – Universidade Federal de Pernambuco. CTG.
Departamento de Engenharia Cartográfica, 2020.

Inclui Referências e Anexo.

1. Engenharia cartográfica. 2. Processamento de imagem. 3.
Sensoriamento remoto. 4. Imagem de alta resolução. 5.
Classificação. 6. Índices físicos. I. Candeias, Ana Lúcia Bezerra
(Orientador). II. Soares, Anderson Reis (Coorientador). III. Título.

UFPE

526.1 CDD (22. ed.)

BCTG/2021-39

SABRINA DE OLIVEIRA GOMES

**APLICAÇÃO DE GEOBIA PARA CLASSIFICAÇÃO DE ÁREA URBANA
UTILIZANDO IMAGENS ÓPTICAS DO PROJETO PE3D**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Cartográfica e de Agrimensura da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do Grau de Bacharel em Engenharia Cartográfica e Agrimensura.

Aprovado em: 13/11/2020.

BANCA EXAMINADORA

Profa. Dra. Ana Lúcia Bezerra Candeias (Orientadora)

Universidade Federal de Pernambuco

Prof. Dr. Anderson Reis Soares (Coorientador)

Instituto Nacional de Pesquisas Espaciais

Prof. Rafael Costa Cavalcanti (Examinador Externo)

Companhia Pernambucana de Saneamento

Prof. João Rodrigues Tavares Junior (Examinador Interno)

Universidade Federal de Pernambuco

AGRADECIMENTOS

Agradeço aos meus pais, Adriana e Sergio, por estarem sempre ao meu lado, por mostrarem o caminho para me tornar o que sou hoje e acreditarem no meu sonho. Jamais vou esquecer todo o esforço que fizeram por mim.

Agradeço ao meu irmão, Sérgio, por toda apoio, por ser um exemplo de dedicação e superação. Agradeço ao meu melhor amigo Alexandre Orlando por toda torcida e confiança depositada em mim.

Agradeço a minha Orientadora Dra. Ana Lúcia, por me instruir desde o início da graduação e me acompanhar até o final da mesma com toda dedicação de sempre, em conjunto agradeço ao meu Coorientador Dr. Anderson Reis por toda orientação para desenvolver esse projeto da melhor forma possível.

Agradeço a todos os professores do Departamento de Engenharia Cartográfica, pelos ensinamentos, tornando possível minha formação acadêmica.

Agradeço aos meus supervisores de estágio, Mrs^a. Anny Dias, Mrs. Márcio Silva, Mrs. Adauto Ferreira e Mrs^a. Catarina Ribeiro, por contribuírem no meu crescimento profissional e por toda orientação ao longo do estágio.

Agradeço aos meus colegas e amigos da Gerência de Cadastro e Geoprocessamento (GCG), Rafael Cavalcanti, Túllio Aullus, Victor Mogollon, Anny Dias, Paulo Moraes e Lenin Caldeira, pela confiança no meu desempenho profissional e por cada ensinamento durante o dia a dia de trabalho.

A COMPESA por ter cedido o material para esse trabalho, a banca desse trabalho de conclusão de curso e ao Projeto: MORFOLOGIA MATEMÁTICA APLICADA A IMAGENS DE MULTISENORES PARA ESTUDOS AMBIENTAIS, Processo:439610/2018-4, CHAMADA UNIVERSAL MCTI/CNPQ.

E por fim, agradeço aos meus amigos da graduação, em especial as minhas grandes amigas Evelyny Matias, Camila Lira e Carine Cavalcanti, que estão comigo desde o início, apoiando, torcendo e partilhando os momentos difíceis e felizes da graduação, vocês tornaram tudo mais leve.

Dedico esse trabalho a toda a minha família, em especial ao meu querido avô, Sr. José Bezerra.

RESUMO

O espaço urbano é complexo e, possui grande variabilidade dos alvos e muitas vezes são objetos pequenos, como telhados residenciais. Os métodos de extração de informação, automatizado ou manual, apresentam limitações e dificuldades, como complexidade dos alvos, subjetividade da interpretação do analista e o tempo demandado para isso. Apesar das imagens de alta resolução possibilitarem uma melhor visibilidade dos alvos urbanos, existe uma dificuldade em discriminar automaticamente os alvos, devido à complexidade do ambiente urbano e os alvos com respostas espectrais semelhantes. A utilização das camadas auxiliares e pré-processamentos na imagem podem auxiliar processo da classificação. Esse trabalho apresenta uma semiautomação da extração de feições para auxiliar na vetorização de quadras, logradouros e lotes. Utilizou-se como área teste, um loteamento em Caruaru, Pernambuco. Os resultados podem auxiliar no bloco de Produto Processado e salvo na base da COMPESA (Companhia Pernambucana de Saneamento). O desenvolvimento do trabalho possui as etapas de aquisição da imagem do PE3D, testes para o reconhecimento dos alvos e definição das classes. Foram analisadas a transformação IHS para destaque dos alvos e os índices de vegetação VARI e GRVI. Estes índices foram usados por usarem a faixa do visível. Os índices quando aplicados as imagens de alta resolução permitem visualizar melhor a vegetação e geram destaque para os telhados além de outros alvos. Foram utilizadas quatro classes: Estradas, Solo Exposto, Telhados e Vegetação, afim de contribuir para a geração de mapeamento temático, como também contribuir para a automatização da extração de feições utilizadas para o mapeamento da COMPESA.

Palavras-chave: Processamento de imagem. Sensoriamento remoto. Imagem de alta resolução. Classificação. Índices físicos.

ABSTRACT

The urban space is complex and has great target variability and are often small objects, such as residential roofs. The methods of extracting information, automated or manual, have limitations and difficulties, such as complexity of the targets, subjectivity of the analyst's interpretation and the time required for this. Although high resolution images allow better visibility of urban targets, there is a difficulty in automatically discriminating targets, due to the complexity of the urban environment and targets with similar spectral responses. The use of auxiliary layers and pre-processing in the image can help the classification process. This work presents a semiautomatization of the extraction of features to assist in the vectorization of blocks, public places and lots. A subdivision in Caruaru, Pernambuco, was used as the test area. The results can assist in the Processed Product block and saved at the base of COMPESA (Companhia Pernambucana de Saneamento). The development of the work has the stages of acquisition of the image of the PE3D, tests for the recognition of the targets and definition of the classes. The IHS transformation to highlight the targets and the VARI and GRVI vegetation indices were analyzed. These indexes were used because they use the visible range. The indices when applied to high resolution images allow a better view of the vegetation and generate a highlight for the roofs in addition to other targets. Four classes were used: Roads, Exposed Soil, Roofs and Vegetation, in order to contribute to the generation of thematic mapping, as well as to contribute to the automation of the extraction of features used for the mapping of COMPESA.

Keywords: Image processing. Remote sensing. High resolution image. Classification. Physical indexes.

SUMÁRIO

1	INTRODUÇÃO	9
1.1	CONTEXTO	9
1.2	OBJETIVOS	10
1.2.1	Objetivos específicos.....	11
1.3	JUSTIFICATIVA	11
1.4	ESTRUTURA DO TRABALHO	11
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	IMAGENS DE ALTA RESOLUÇÃO.....	13
2.2	PE3D	13
2.3	GEOBIA – ANÁLISE GEOGRÁFICA DE IMAGENS BASEADAS EM OBJETOS.....	15
2.3.1	Mineração de Dados.....	15
2.3.2	Classificação por Árvore de Decisão	16
2.4	TRANSFORMAÇÃO IHS.....	18
2.5	ÍNDICES DE VEGETAÇÃO.....	19
2.6	VETORIZAÇÃO MANUAL.....	20
3	ÁREA DE ESTUDO	23
4	MATERIAL E MÉTODOS	24
4.1	MATERIAL	24
4.1.1	Dados de Entrada	24
4.1.2	Softwares e Aplicativos	25
4.1.2.1	TerraView e GeoDMA.....	25
4.1.2.2	Spring.....	26
4.2	MÉTODOS	27
4.2.1	Definição da Classes.....	27
4.2.2	Transformação IHS.....	28
4.2.2.1	Segmentação.....	30
4.2.2.2	Classificação por Árvore de Decisão	30
5	DESCRIÇÃO E DISCUSSÃO DOS RESULTADOS.....	33
5.1	AVALIAÇÃO DO EMPILHAMENTO	33
5.2	AVALIAÇÃO DA VETORIZAÇÃO VS. SEGMENTAÇÃO	35
5.3	AVALIAÇÃO DA CLASSIFICAÇÃO.....	42

6	CONSIDERAÇÕES FINAIS	48
	REFERÊNCIAS.....	50
	ANEXO A – PROCESSOS DE EDIÇÃO DA COMPESA	53

1 INTRODUÇÃO

Inicialmente será apresentada uma breve introdução acerca do trabalho.

1.1 CONTEXTO

A COMPESA (Companhia Pernambucana de Saneamento) necessita atualizar seu cadastro para os fins de instalação e cobrança de seus serviços. Ela fornece serviços para todo o estado de Pernambuco. É dividida em duas diretorias principais: a DRM, que cuida da Região Metropolitana do Recife e a DRI que trabalha com a região do interior. Esse trabalho está focado na semiautomatização da extração de feições para auxiliar na vetorização de quadras, logradouros e lotes. Os resultados irão compor o bloco de Produto Processado e salvo na base da COMPESA.

O sensoriamento remoto e o processamento de imagens irão fornecer os recursos para essa automatização. Isso é possível porque os avanços nos sensores orbitais relacionados a melhoria da resolução espacial, espectral, radiométrica e temporal possibilitaram melhorias em estudos urbanos, como uma melhor identificação dos alvos em grandes escalas. É importante ressaltar que atrelado a isso, existe um custo para a obtenção dessas imagens.

O programa Pernambuco Tridimensional (PE3D), é uma iniciativa motivada após as enchentes que atingiram regiões da Mata Sul do Estado de Pernambuco nos anos de 2010 e 2011. Devido a isso, foram realizados mapeamentos das áreas atingidas com a finalidade de controlar futuras inundações, esse mapeamento foi possível a partir de varreduras a laser, onde a Secretária de Recursos Hídricos e Energéticos (SRHE) foi a responsável pelo projeto. O PE3D é uma das metas que foram incluídas no Programa de Sustentabilidade Hídrica de Pernambuco (PSHPE) que tem como finalidade ampliar o acesso a água potável e esgotamento sanitário para a população. Dessa forma, o PE3D vem com o objetivo de gerar todo o mapeamento do Estado, disponibilizando esses produtos gratuitamente.

Uma base de dados espaciais obtida a partir do recobrimento aerofotogramétrico e perfilamento a laser traz um desenvolvimento positivo para a região, gerando uma base sólida para o campo acadêmico e empresarial. Um dos produtos que foram gerados a partir do programa foram as Ortofotos na escala de

1:5000 que foram elaboradas a partir do recobrimento aerofotogramétrico, com uma resolução espacial de 50cm, o que permite uma boa distinção dos alvos em regiões intraurbanas. Diante disso, esses produtos trazem a possibilidade de estudos em cenários urbanos a partir de técnicas de extração de informações de imagens.

Segundo Meneses et. al. (2012), o processamento de imagens consiste na execução de operações matemáticas dos dados, visando as suas transformações em imagens de melhores qualidades espectrais e espaciais e que sejam mais apropriadas para uma determinada aplicação. A análise de Imagens Baseada em Objeto Geográfico (GEOBIA) é uma técnica que objetiva individualizar o objeto a partir de agrupamentos de pixels que são semelhantes em função dos aspectos espectrais e espaciais, como também considerando atributos quanto á forma, tamanho e entre outros (Blaschke. et. al., 2014).

Para realizar a individualização dos objetos é importante utilizar algumas técnicas, como a mineração de dados, que permite que sejam descobertos padrões para análise de dados a partir de processamentos por meio de algoritmos. Segundo Wintten et. al. (2011), a mineração de dados é um processo automático ou semiautomático, de descoberta de padrões nos dados. Normalmente os dados estão agrupados em quantidades consideráveis, como na GEOBIA, logo, a descoberta dos padrões deve ser significativa de forma que traga vantagem para a classificação da imagem.

A descoberta de padrões nos dados permite relacionar os dados a uma certa classe. Para isso, é possível determinar um conjunto de regras para classificação por meio de uma árvore de decisão. Essa estrutura de classificação é composta por nós folhas que contêm as classes e os nós intermediários são os atributos baseados em testes possuindo um ramo para cada possível saída.

Dessa forma, este trabalho tem como objetivo geral determinar uma metodologia para a extração de alvos urbanos e geração de mapeamento temático do ambiente urbano para o auxílio de tomadas de decisões no território.

1.2 OBJETIVOS

O objetivo do trabalho é determinar uma metodologia para a extração automatizada de alvos urbanos para mapeamentos temáticos do ambiente urbano, para que contribuam para tomadas de decisões sobre o território.

1.2.1 Objetivos específicos

- a) Aplicar uma metodologia que seja possível gerar auxílio na automatização da extração de alvos para o mapeamento da COMPESA (Companhia Pernambucana de Saneamento);
- b) Gerar mapeamento temático da área urbana comparando os resultados entre as imagens Original e IHS;
- c) Estudar a extração de alvos urbanos quadras, lotes, vegetação e estradas, utilizando imagens na faixa do visível e aplicação da Transformação IHS;
- d) Utilizar índices de Vegetação GRVI e VARI a partir de imagens na faixa do visível para auxílio de tomadas de decisões quanto a classificação dos alvos;
- e) Realizar a Classificação por árvore de decisão das imagens.

1.3 JUSTIFICATIVA

A COMPESA utiliza uma metodologia manual para a extração de alvos, sendo eles intitulados de quadras e lotes, essa metodologia demanda um tempo considerável para execução, tendo em vista que o técnico necessita analisar a área que será mapeada e conseqüentemente gera uma necessidade de ter muita mão de obra para esse serviço, visto que essa atividade gera mapeamento para a empresa onde a mesma é responsável por todo abastecimento do Estado de Pernambuco e necessita de informação cartográfica atualizada para realizar suas tomadas de decisões.

Diante disso, a motivação desse trabalho se deu em realizar uma metodologia que possibilite uma automatização da extração dos alvos de interesse da empresa, para que isso possibilite a substituição ou diminuição do processo de vetorização manual da empresa.

1.4 ESTRUTURA DO TRABALHO

Este trabalho está dividido em 6 partes. No capítulo 1 será apresentado uma breve introdução contendo o contexto, objetivos, objetivos específicos e justificativa. O capítulo 2 será a fundamentação teórica contendo informações sobre toda a teoria

necessária para o desenvolvimento do trabalho. No capítulo 3 será apresentado a área de estudo e suas características. No capítulo 4 os materiais e métodos utilizados. O capítulo 5 é reservado para a apresentação e discussão dos resultados encontrados. O capítulo 6 é reservado para as considerações finais acerca do trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo será exposto os conceitos básicos para a metodologia utilizada.

2.1 IMAGENS DE ALTA RESOLUÇÃO

Estudos em áreas urbanas apresentam diversas dificuldades, em especial devido ao nível de detalhamento dessas áreas torna a atividade de extração de informações uma tarefa nada fácil. As imagens de alta resolução apresentam a possibilidade da utilização de estudos em áreas urbanas, pois quanto maior a resolução espacial, maior o detalhamento dos alvos da imagem, com isso, é possível perceber a heterogeneidade dos materiais presentes nesses ambientes. Apesar disso, é possível também encontrar respostas espectrais semelhantes em alvos distintos e que não necessariamente pertencem a mesma classe.

Além das dificuldades existentes entre alvos com respostas espectrais muito semelhantes, existe a dificuldade que a imagem pode apresentar, sendo ela bidimensional pode gerar dúvidas quanto alguns detalhes apresentados, pois nem sempre o processo atende a realidade do local, pois efeitos como sombra podem dificultar e gerar erros no momento da classificação, e devido a resolução espacial, imagens de alta resolução podem apresentar essas características.

Segundo Pinheiro (2003), as imagens de alta resolução permitem uma análise detalhada para estudos de áreas com sensibilidade ambiental, como também para monitorar e planejar cidades. Ainda segundo o autor, é importante analisar a funcionalidade do método de classificação de imagens orientado ao objeto junto a imagens de alta resolução.

2.2 PE3D

O Pernambuco Tridimensional (PE3D), é uma plataforma que visa dar suporte a projetos de vários segmentos. Foi idealizado após enchentes que ocorreram nos anos de 2010 e 2011 nos municípios da Mata Sul do Estado de Pernambuco. Na época o serviço visava mapear apenas as principais áreas afetadas e as calhas dos principais rios das bacias hidrográficas atingidas. O mapeamento consistiu em uma varredura a laser (LiDAR) do terreno, a

varredura a laser permite um levantamento tridimensional de pontos do terreno, permitindo obter com rapidez e qualidade as informações altimétricas do terreno, e assim gerou um sistema de prevenção para o estado em casos de enchentes, essa etapa foi realizada por meio da Secretaria de Recursos Hídricos e Energéticos (SRHE).

Posteriormente foi ampliado a área de levantamento para todo o estado de Pernambuco, utilizando o recobrimento aerofotogramétrico, compreendendo o imageamento de todo o estado com utilização de sensores passivos e o perfilamento a laser (LiDAR). Atualmente o programa está inserido nas metas do Programa de Sustentabilidade Hídrica de Pernambuco (PSHPE), financiado pelo Banco Mundial e gerenciado pela Secretaria de Desenvolvimento Econômico (SDEC).

O serviço tem dois níveis de precisão, o primeiro que abrangeu todo o território de Pernambuco a partir do recobrimento aerofotogramétrico e geração de ortofotos na escala de 1:5000, perfilamento a laser com precisão altimétrica acima de 25cm e geração de Modelos Digitais de Elevação (MDE). O segundo abrangeu uma área de 870km, contemplando 26 municípios, a partir de um recobrimento aerofotogramétrico e geração de ortofotos na escala de 1:1000, perfilamento a laser com precisão melhor que 10cm e geração de produtos como Modelos Digitais do Terreno (MDT), Modelos Digitais de Elevação (MDE) e Imagens Hipsométricas.

Com o serviço de recobrimento aerofotogramétrico e perfilamento a laser, os dados foram validados e certificados pelo Instituto de Tecnologia de Pernambuco (Itep), seguindo três etapas de validação: Análise de Completude, Análise de Consistência e Análise Estatística da Precisão Planimétrica, e assim o conjunto de dados foi apresentado de forma digital e gratuita, permitindo o acesso e download de todo conteúdo.

Os materiais disponíveis variam de Ortofotos na escala de 1:5000 e 1:1000, precisão altimétrica melhor que 25cm e 10cm, respectivamente, e geração de Modelos Digitais de Terreno (MDT), Modelos Digitais de Elevação (MDE) e Imagens Hipsométricas, todo os produtos estão referenciados no Sistema de Coordenadas Projetadas UTM SIRGAS 2000, fuso 24S ou 25S.

Senso assim, o PE3D visa atender o setor empresarial, o campo acadêmico, as áreas ambientais e o ambiente urbano, eles afirmam que “deve-se ressaltar o potencial do PE3D para o controle da expansão urbana em bases sustentáveis.”

(PE3D, 2016), dado que o material possibilita a tomada de decisões pelo poder público e o estudo do crescimento urbano nas cidades.

2.3 GEOBIA – ANÁLISE GEOGRÁFICA DE IMAGENS BASEADAS EM OBJETOS

GEOBIA é uma abordagem de classificação que utiliza objetos para classificação. Ela se difere em especial pelo uso de diferentes técnicas de processamento de imagens como a segmentação e a mineração de dados.

Essa abordagem tem por objetivo individualizar os alvos contidos na imagem. Para isso, a técnica de segmentação é empregada para delimitar regiões homogêneas, chamadas de objetos, sobre as quais, usualmente, são construídas uma série de regras para sua classificação.

De acordo com Platt e Raposa (2008), a GEOBIA tem um excelente potencial para evoluir e melhorar a precisão e classificação do uso da terra quando comparada ao método tradicional de pixel a pixel, mesmo com imagens de média resolução. Segundo BLASCHKE et. al. (2014), a GEOBIA é uma evolução para os métodos de classificação, pois utiliza de ferramentas específicas, softwares, métodos e diversas regras e linguagem.

Silva et. al. (2017), considera satisfatório o uso da classificação orientada a objeto em imagens orbitais de média resolução espacial, sendo possível aplicar o estudo em áreas de análises de mudanças de uso e cobertura da terra.

2.3.1 Mineração de Dados

O mercado em geral como as grandes indústrias, empresas comerciais e o meio acadêmico trabalham diariamente com uma grande quantidade de dados, e sentem a necessidade de trabalhar com essas informações de forma eficaz e ágil. As técnicas de mineração de dados tornam-se um atrativo pois possuem um excelente potencial para transformar uma grande quantidade de dados em informações uteis, aumentando a capacidade de análise e conhecimento sobre o dado, e em um tempo reduzido de processamento.

O sensoriamento remoto e a aerofotogrametria geram produtos matriciais (imagens) que possuem uma grande quantidade de dados e que necessitam serem bem processados para futuramente serem analisados e conseqüentemente gerar uma vasta quantidade de informação útil a sociedade. Dessa forma é possível

observar que as técnicas de mineração de dados são cruciais para o manejo com as imagens e assim realizar a extração da informação.

A mineração de dados é um processo que tem como finalidade descobrir padrões contidos em vastos conjuntos de dados. Bento (2017) afirma que, a mineração de dados consiste em trabalhar dados brutos em um formato mais apropriado para análises, que são divididos em pré-processamento e pós-processamento. Ainda segundo o autor, o pré-processamento dos dados consiste na fusão dos dados, limpeza para remoção dos ruídos, observações duplicadas, seleção de registros e características importantes para a mineração, enquanto o pós-processamento assegura que os resultados válidos e úteis sejam considerados.

Segundo Körting (2009), a utilização da mineração de dados aumenta o potencial de análises e aplicações de dados provenientes do sensoriamento remoto, facilitando estudos em áreas urbanas que possuem a dificuldade de distinguir a diferença entre os alvos, o que necessita da utilização de técnicas mais aprimoradas para extração dos dados.

Segundo Souza (2012), é fundamental conhecer os tipos de variáveis envolvidas e a inteligibilidade do modelo de conhecimento gerado, e assim definir a forma de aprendizado do algoritmo, é possível optar pelos modelos: Supervisionado, onde o modelo de conhecimento é abstraído a partir de um conjunto de treinamento e avaliado a partir do conjunto de teste, e Não-Supervisionado, onde não existe a informação de saída desejada, e os algoritmos partem dos dados procurando estabelecer relações entre si.

Com os dados preparados podemos utilizar diversos modelos derivados da mineração dados, como: métodos baseados em redes neurais, métodos estatísticos e árvores de decisão (BENTO, 2017; RUIZ, 2017; SOUZA, 2012).

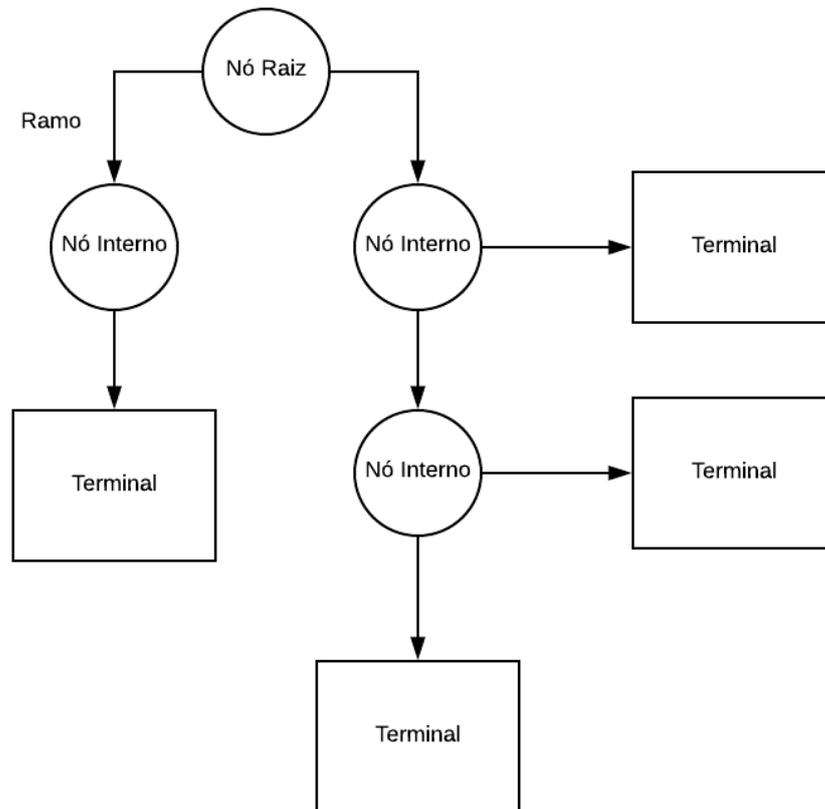
2.3.2 Classificação por Árvore de Decisão

A árvore de decisão é um algoritmo que pode ser utilizada na mineração de dados, assim como, possibilitando realizar a classificação. De acordo com Basgalupp (2010), a classificação pode ser entendida como uma tarefa de aprender uma função denominada alvo f que mapeia um conjunto de atributos denominado x .

Souza (2012) explica que, a árvore de decisão (Figura 1) pode ser constituída como um fluxograma, sendo estruturado como uma árvore, nela temos que: o nó

interno indica um teste em um atributo, os ramos representam um resultado do teste e cada nó-folha ou nó terminal possui um rotulo da classe.

Figura 1 – Modelo de uma árvore de decisão



Fonte: A Autora, 2020.

O nó superior é a raiz da árvore, os nós internos representam uma decisão que recairá sobre os atributos, eles passam pelos ramos que saem de um nó-interno, os ramos são os valores de atributos naquele nó e o terminal (folha) recebe o rotulo que é o nome da classe definida. Para estruturar a árvore de decisão é necessário que o usuário tenha um nível de conhecimento sobre os atributos e que defina previamente suas classes.

Ainda segundo Basgalupp (2010), o número de árvores de decisão possíveis para um determinado problema pode ser estruturado de muitas maneiras, o número de possibilidades cresce fatorialmente à medida que o número de atributos aumenta, logo, é impraticável esperar uma estrutura de árvore de decisão ótima.

Diversos trabalhos comprovam o bom desempenho da utilização de árvores de decisão em classificações de imagens, como: Ruiz (2017), Bento (2017), Souza

(2012). Bento (2017), afirma que, as principais vantagens do uso de árvores de decisão na classificação de imagens residem na eficiência em questão de tempo de processamento para lidar com um extenso número de dados e o fornecimento de uma forma intuitiva de analisar os resultados.

2.4 TRANSFORMAÇÃO IHS

A representação do espaço RGB é definida por três quantidades de cores primárias, o Red (Vermelho), Green (Verde) e Blue (Azul), porém existe o espaço de cores conhecido por IHS (Intensity, Hue, Saturation), onde é uma transformação e uma forma alternativa do espaço de cores RGB. Nesse espaço, as cores são definidas por atributos, sendo elas Intensidade, Matiz e Saturação. O problema das imagens coloridas RGB é que os ajustes das cores que são feitos nos monitores, através de manipulações de ganho e brilho aplicados a cada cor básica, alteram simultaneamente os valores de intensidade, matiz e saturação, prejudicando assim, o processo de análise visual dos objetos presentes na imagem (Dutra e Meneses, 1986, 1987).

O IHS apresenta diversas vantagens em relação ao espaço de cores RGB, segundo Crosta (1992), tem a vantagem de apresentar as cores de uma maneira mais próxima a utilizada pelo sistema de visão humana.

Santos et. al. (2010), explica que, o sistema IHS possui um controle individual de seus componentes e os seus três parâmetros podem ser analisados e modificados separadamente.

Ainda segundo o autor, matiz é a medida do comprimento de onda médio da luz que reflete ou emite de um objeto, dessa forma, ela define a cor do objeto; a intensidade é responsável pela sensação de brilho sobre o olho humano, ela está relacionada a quantidade de energia total envolvida em todos os comprimentos de onda, equivale a visualizar uma cena colorida, porém com uma visão preto e branco, ela é independente dos atributos saturação e matiz que são atributos de cor; a saturação é o intervalo de comprimentos de onda ao redor do comprimento de onda média onde a energia é refletida ou emitida, apresentando um alto valor de saturação que significa em uma cor espectralmente pura, ou um baixo valor que indica uma mistura de comprimentos de onda, que representa cores mais apagadas.

2.5 ÍNDICES DE VEGETAÇÃO

As regiões do visível e do infravermelho próximo são muito utilizados para analisar propriedades espectrais da vegetação, explorando parâmetros biofísicos da cobertura vegetal, a partir da utilização de índices de vegetação. O trabalho vai abordar dois índices que utilizam a banda do visível: i) Green-Red Vegetation Index (GRVI); II) Visible Atmospherically Resistant (VARI).

O GRVI é um índice utilizado para distinguir classes de ocupação do solo, sendo um ótimo indicador para a presença de vegetação. Segundo Oliveira (2019), o cálculo do índice GRVI pode ser realizado a partir da seguinte fórmula:

$$GRVI = a \left[\frac{Green - Red}{Green + Red} \right] + b \quad (1)$$

O VARI é um índice de vegetação utilizado para medir o estresse da vegetação. O índice é calculado da seguinte forma:

$$VARI = a \left[\frac{Green - Red}{Green + Red - Blue} \right] + b \quad (2)$$

Os resultados adquiridos a partir de índices de vegetação são números pequenos e fracionários, para que seja possível a exposição do mesmo no monitor de vídeo, eles devem ser multiplicados por um valor escalar (a) para se enquadrarem no intervalo de 0 a 255 de uma imagem de 8 bits. Uma constante (b) é somada aos valores reescalados para apenas obter um offset do histograma para uma posição mais central entre 0 a 255, com objetivo de possibilitar um equilíbrio no realce da imagem (MENEZES & ALMEIDA, 2012).

Os valores utilizados para os índices foram de Silva (2020) do trabalho intitulado de “Classificação da cobertura do solo urbano utilizando imagens aéreas, produtos *LiDAR*, índices de vegetação e razão de bandas”, onde a autora a partir de testes utilizou os valores de 10 e 50, respectivamente para (a) e (b), valores esses que melhor se enquadraram para a visualização.

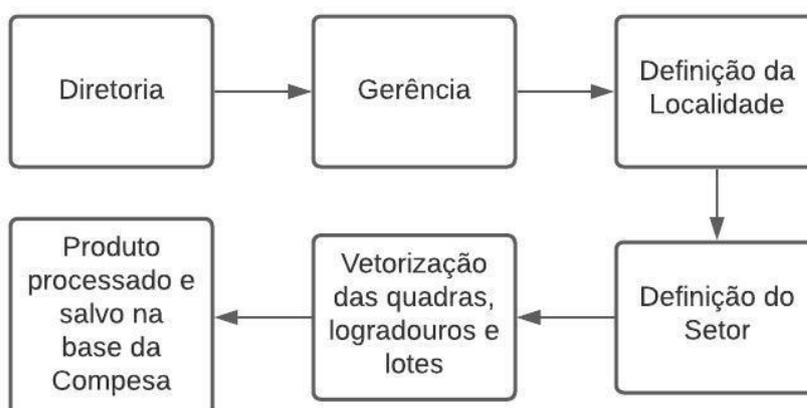
2.6 VETORIZAÇÃO MANUAL

A vetorização tem como objetivo extrair informações da imagem. A vetorização do trabalho foi disponibilizada pela COMPESA, e para que o procedimento seja feito existe um fluxo que deve ser seguido.

Diferente da divisão geográfica já conhecida nas bibliografias, a COMPESA a partir de seus interesses em relação a áreas de abastecimento de água tem sua própria divisão administrativa. Inicialmente elas partem da divisão da Diretoria, definidas por duas Diretorias, a Diretoria Regional da Metropolitana (DRM) e a Diretoria Regional do Interior (DRI). A DRM contempla toda a região metropolitana do Recife, enquanto a DRI contempla as regiões do agreste e sertão. A gerência é responsável por administrar as localidades, onde as localidades são divisões administrativas criadas considerando-se a operação de distribuição de água e coleta de esgoto da região, podendo pertencer a mais de um município, dentro de cada localidade existem os setores comerciais, que são porções das localidades.

A partir das divisões realizadas o procedimento de vetorização é iniciado, cada técnico é responsável por uma localidade e conseqüentemente por um setor e assim deve-se iniciar o processo de vetorização, a partir de delimitação de quadras, logradouros e lotes, dessa maneira gerando o material que é salvo no Banco de Dados Geoespaciais e pode servir para diversos projetos da empresa. Na Figura 2 é possível observar o fluxo para definição e geração da cartografia.

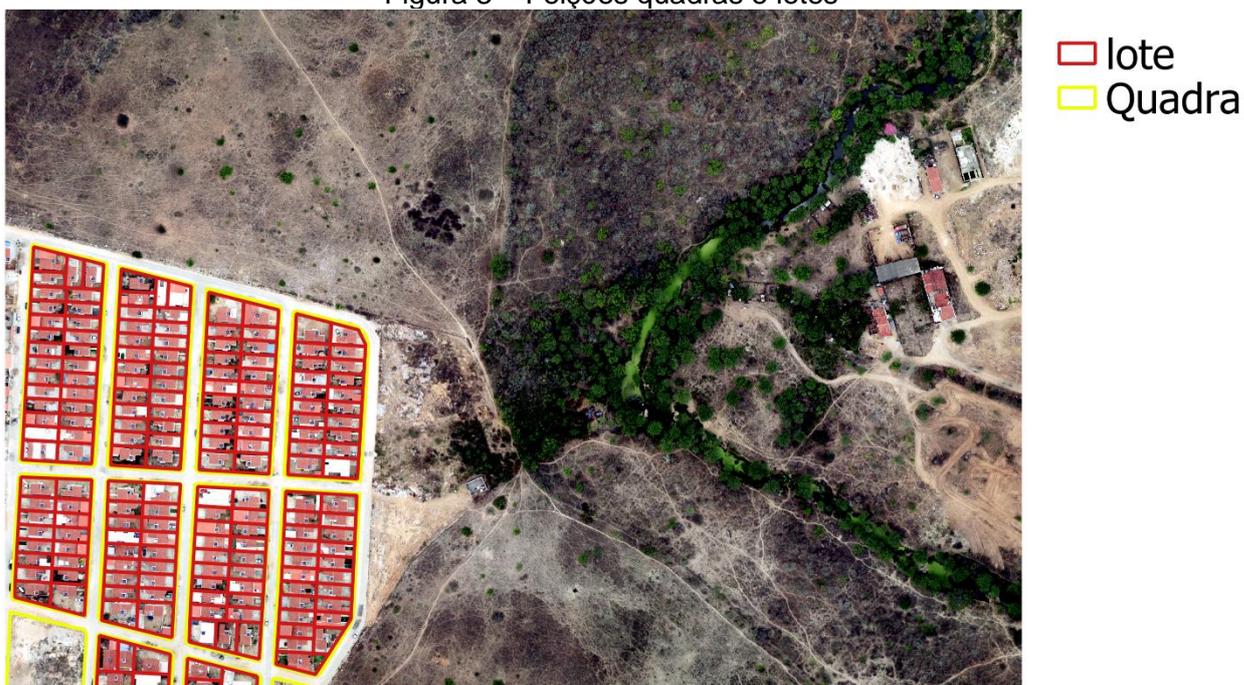
Figura 2 – Fluxo de produção do geoprocessamento



Fonte: A Autora, 2020.

Essa é uma forma de comparar como o processo de segmentação e vetorização manual podem trazer resultados diferentes na definição de agrupamentos de alvos homogêneos. Na Figura 3 é possível visualizar as feições de quadra e lote vetorizadas manualmente em uma área da imagem.

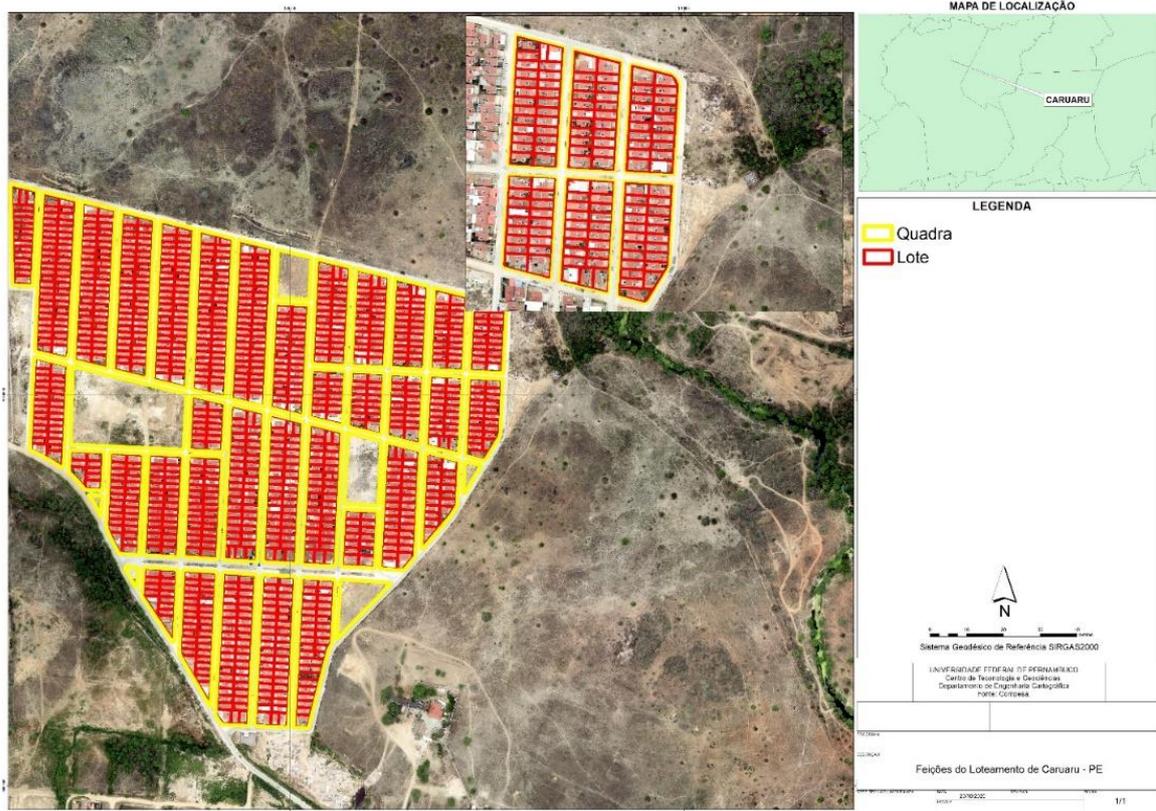
Figura 3 – Feições quadras e lotes



Fonte: Autora, 2020.

As quadras são definidas por conjuntos de lotes, que agrupadas em um polígono definem os limites da quadra, enquanto que os lotes são definidos pelas áreas dos imóveis. As feições do loteamento podem ser vistas na Figura 4.

Figura 4 – Feições do loteamento

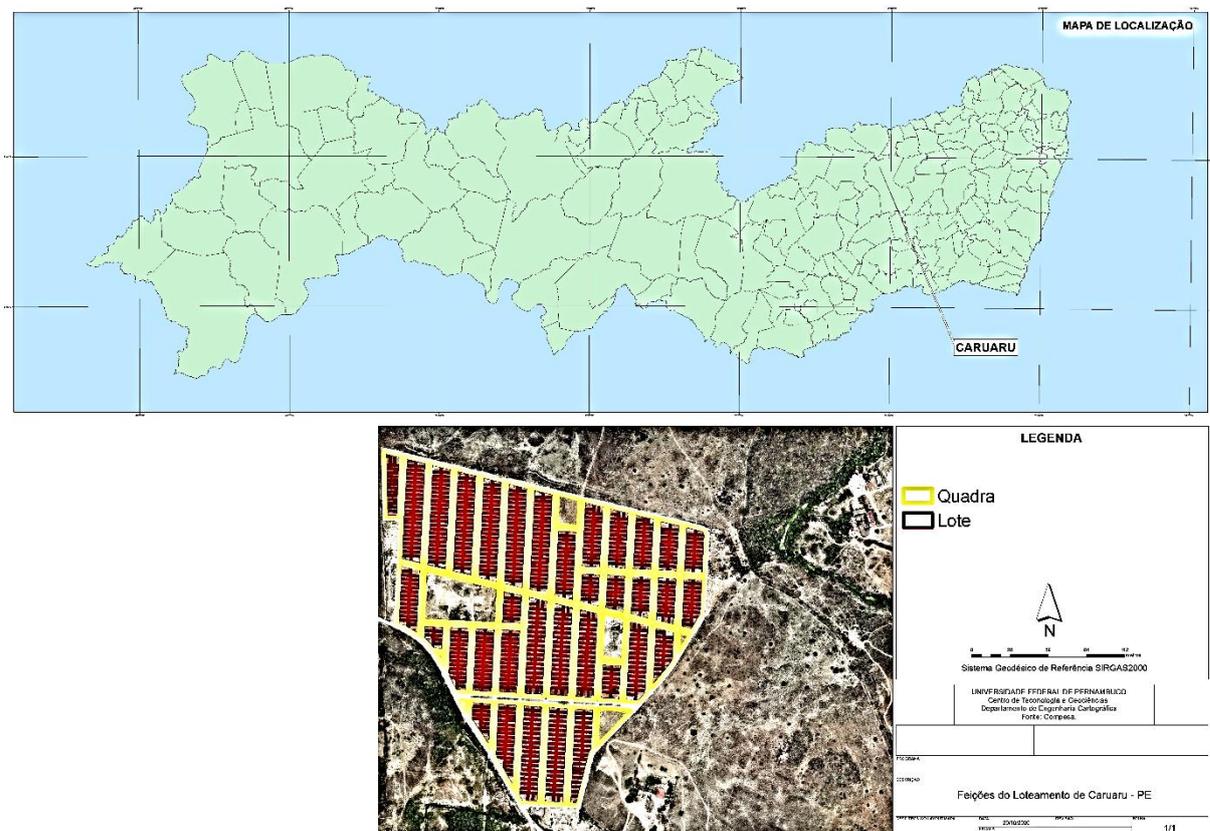


Fonte: A Autora, 2020.

3 ÁREA DE ESTUDO

A área teste está localizada em Caruaru, Pernambuco e foi delimitada considerando alguns aspectos da região, o ponto analisado foi a diversidade dos alvos na articulação para que fossem capazes de serem distinguidos ao olho humano (Figura 5). A importância de aplicar a área teste em um ambiente urbano é que existe uma significativa heterogeneidade no uso e ocupação do solo. Logo, foram considerados os alvos: vegetação, telhados, solo exposto e estrada.

Figura 5 – Mapa da área de estudo



Fonte: A Autora, 2020.

A área é caracterizada por um ambiente urbano, chamada de área de loteamento, que tem por característica ter um crescimento ordenado quanto a sua urbanização, com presença de imóveis residenciais onde a maioria é caracterizada por casas, contém logradouros asfaltados, uma porção de área verde e área de solo exposto. Além disso, as áreas no entorno do loteamento também serão considerados no estudo, visto que mostra outras características como a vegetação mais densa.

4 MATERIAL E MÉTODOS

Neste capítulo será descrito os dados utilizados, os softwares e aplicativos, como também os procedimentos metodológicos na realização do trabalho.

4.1 MATERIAL

Abaixo será apresentado detalhadamente todo o material utilizado para o desenvolvimento do trabalho.

4.1.1 Dados de Entrada

a) Matriciais:

As imagens adquiridas foram disponibilizadas pela Companhia Pernambucana de Saneamento (COMPESA) advinda do PE3D.

1. Ortofoto do Município de Caruaru em formato GeoTIFF com escala de 1:5000, resolução espacial de 50cm, resolução radiométrica de 8bits, referenciado no Sistema de Coordenadas Projetadas UTM SIRGAS 2000 fuso 24S.

b) Vetoriais:

1. Foram utilizados os limites territoriais do Estado de Pernambuco e do Município de Caruaru, no formato shapefile (.shp) adquiridos da base vetorial disponibilizada gratuitamente pelo Instituto Brasileiro de Geografia e Estatística (IBGE).
2. A vetorização das feições da imagem foram adquiridas da Companhia Pernambucana de Saneamento (COMPESA), disponibilizadas pela Gerência de Cadastro e Geoprocessamento (GCG) que é responsável por realizar as definições das feições da imagem a partir de vetores denominados de Quadras, Lotes e Logradouros.

4.1.2 Softwares e Aplicativos

Abaixo será apresentado todos os Softwares e Aplicativos necessários e fundamentais para o desenvolvimento do trabalho.

4.1.2.1 TerraView e GeoDMA

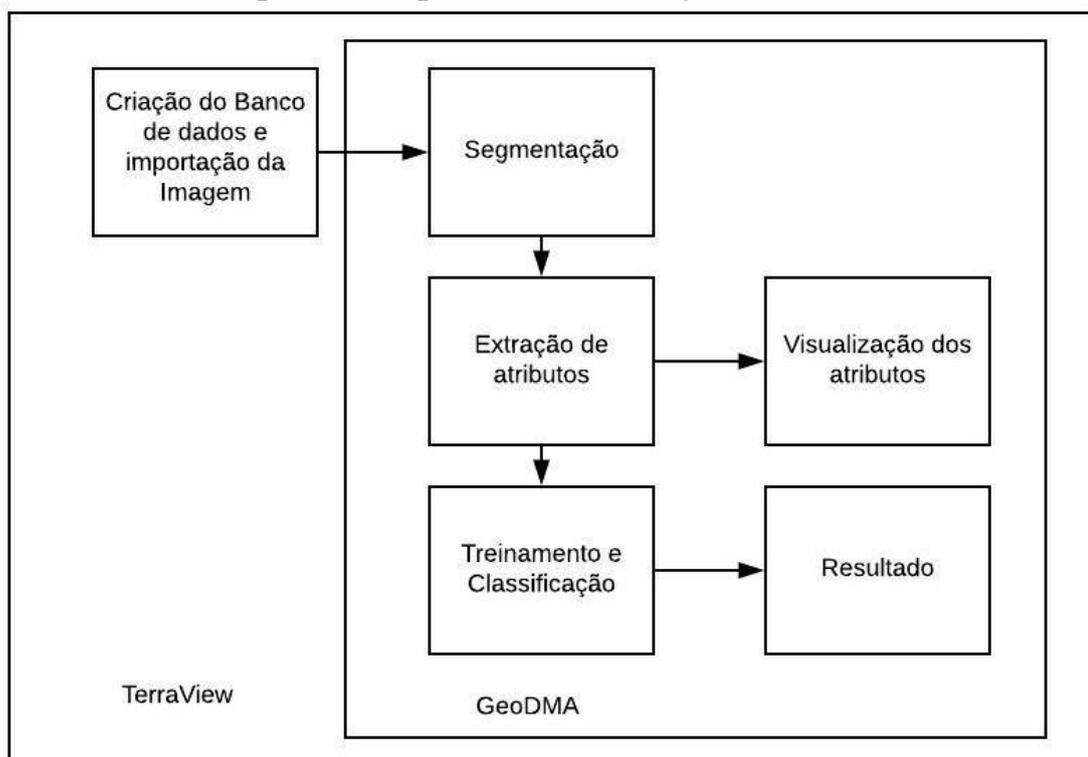
O TerraView é um aplicativo desenvolvido a partir de uma biblioteca de software de geoprocessamento aberta chamada TerraLib, construído pelo Instituto Nacional de Pesquisas Espaciais – INPE, que tem como objetivo apoiar o desenvolvimento de aplicativos geográficos personalizados. O TerraView é um visualizador de dados geográficos que permite uma análise avançada de dados vetoriais e matriciais, onde esses dados podem ser armazenados em um Sistema de Gerenciamento de Banco de Dados (SGBD). O TerraView tem os seguintes objetivos principais:

- a) Ser um aplicativo de fácil utilização, com recursos de visualização e análises de dados;
- b) Demonstrar a utilização da biblioteca do TerraLib.

É importante ressaltar que, o aplicativo TerraView apenas manipula os dados existentes, ou seja, ele não permite que sejam feitas construções de dados geográficos. O TerraView tem como uma das suas funções gerenciar o banco de dados e manipular as imagens, enquanto que a ferramenta GeoDMA realiza todo o processo necessário para que seja feita a classificação da imagem.

Na Figura 6 é possível visualizar o fluxograma das etapas realizadas. Körting et. al. (2009), apresenta uma visualização mais detalhada do diagrama e do funcionamento do GeoDMA junto ao TerraView.

Figura 6 – Diagrama de blocos do processamento



Fonte: A Autora, 2020.

O *Geographical Data Mining Analyst* conhecido como GeoDMA é um plugin desenvolvido para o sistema TerraView e funciona para realizar análises de imagens a partir de técnicas de mineração de dados, sendo uma poderosa ferramenta para aplicações de técnicas de sensoriamento remoto. O plugin tem as seguintes atividades principais:

- Segmentação;
- Extração de atributos;
- Visualização de atributos;
- Classificação;
- Visualização.

4.1.2.2 Spring

O Spring é um software desenvolvido pelo INPE (Instituto Nacional de Pesquisa Espacial) e a DPI (Divisão de Processamento de Imagens) com diversos parceiros, que possui a funcionalidade de um SIG (Sistema de Informações

Geográficas) com funções de processamento de imagens, análises espaciais, modelagens de terreno e entre outros.

Os objetivos principais do software é possibilitar as seguintes atividades:

- Construção de um Sistema de Informação Geográfica de rápida aprendizagem, acessível e possível de aplicar em diversas áreas de estudo;
- Unificação de um ambiente de Geoprocessamento e Sensoriamento remoto.

4.2 MÉTODOS

Abaixo será apresentado cada método necessário para o desenvolvimento do trabalho, detalhando todo o processo.

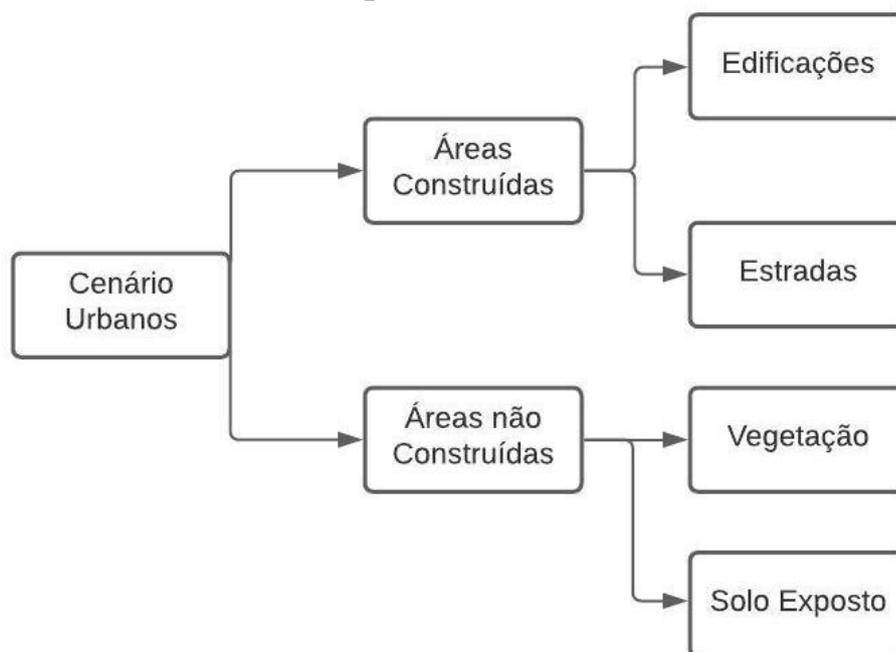
4.2.1 Definição da Classes

Para a definição das classes (Figura 7), foi realizada uma prévia análise visual das características da área.

A área do loteamento possui quatro classes visivelmente marcantes, as áreas construídas caracterizadas por edificações e estradas e as áreas não construídas, caracterizadas por vegetação e solo exposto.

As quadras são definidas a partir de agrupamento de lotes, definidas pelos telhados e junto a isso tem-se os segmentos das estradas, que possibilitam melhorar a definição das quadras. Essas classes foram definidas para melhor caracterizar o ambiente de estudo.

Figura 7 – Classes



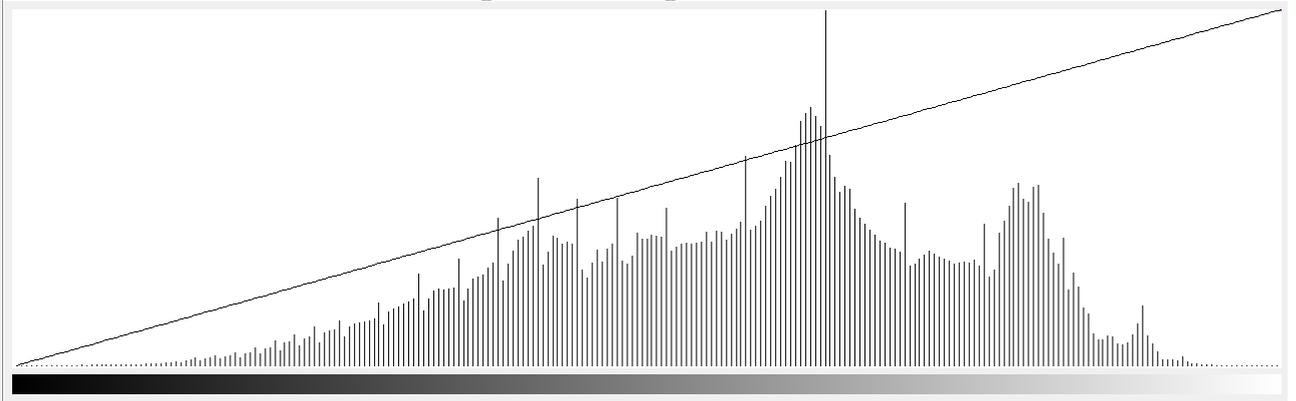
Fonte: A Autora, 2020.

4.2.2 Transformação IHS

Para realizar a transformação IHS, foram utilizadas as três bandas da faixa do visível da imagem adquirida, sendo elas a R (red), G (green) e B (blue), o resultado esperado é que cada pixel da imagem irá possuir algo correspondente ao espaço IHS. Logo, obtendo o resultado procurou-se analisar o histograma da imagem, pois o mesmo pode ser útil, devido que, é possível descrever a distribuição dos níveis de cinza da imagem.

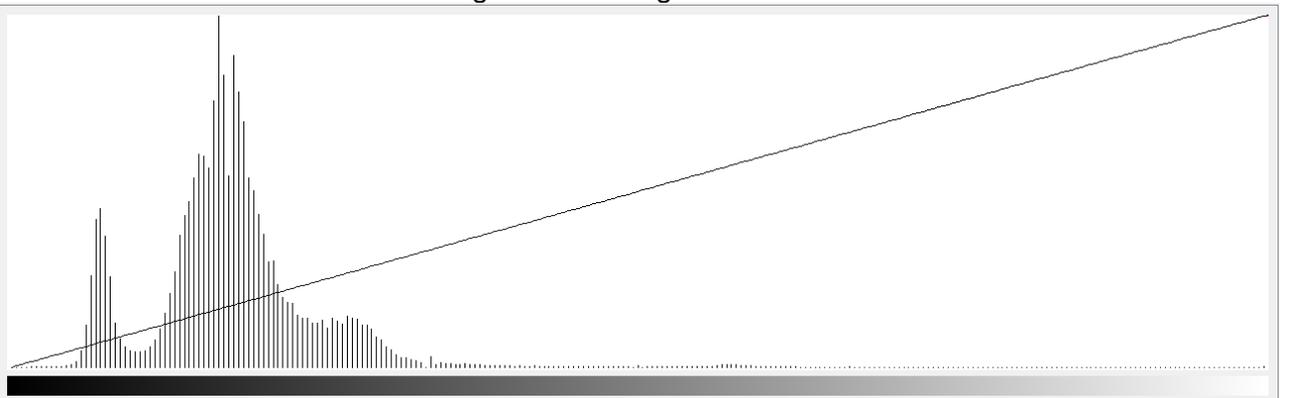
O histograma indica a qualidade da imagem quanto aos contrastes e intensidade luminosa. É possível perceber que na Figura 8, o histograma de I (intensidade), responsável pela sensação de brilho, apresenta um alto contraste e por ter uma boa distribuição no seu histograma sua luminosidade não está caracterizada nem como alta (clara) ou baixa (escura). Enquanto que na Figura 9, H (Hue – Matiz) e na Figura 10, S (Saturação) possuem pouco contraste e uma baixa luminosidade.

Figura 8 – Histograma I



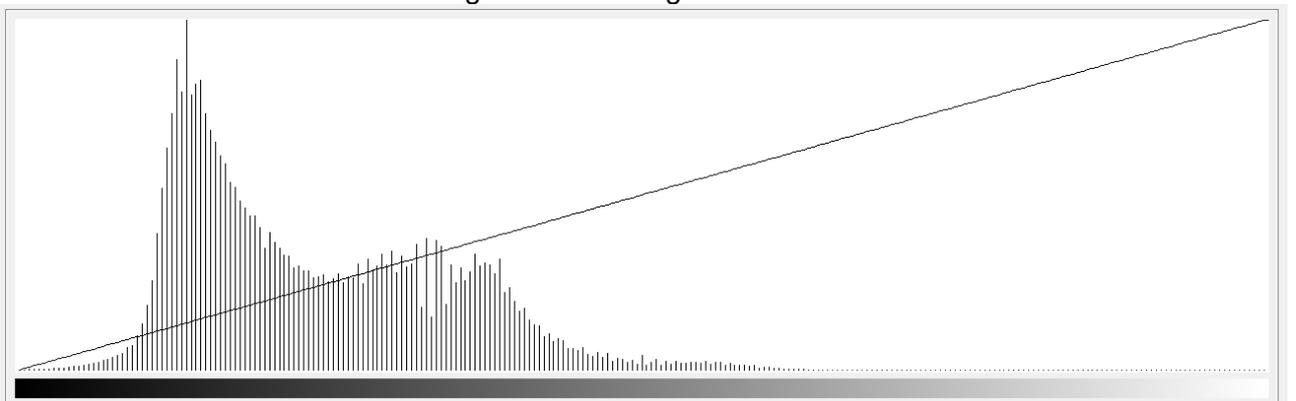
Fonte: A Autora, 2020.

Figura 9 – Histograma H



Fonte: A Autora, 2020.

Figura 10 – Histograma S



Fonte: A Autora, 2020.

4.2.2.1 Segmentação

Para visualizar e manusear a imagem no software TerraView, é necessário criar um banco de dados e dessa forma importar a imagem para o software. Através da ferramenta GeoDMA que realiza o processo de classificação.

A primeira etapa para aplicação da GEOBIA é segmentar a imagem. Segundo Paulo et. al (2012), a segmentação produz representações vetoriais, que são geradas a partir dos pixels com respostas semelhantes. Ou seja, a imagem será dividida por regiões, essas regiões são conjuntos de pixels contíguos que se apresentam uniformemente na imagem. O mesmo autor afirma que a qualidade desse agrupamento depende da técnica utilizada, dos parâmetros que são definidos pelo usuário e das características das bandas disponíveis na imagem.

Para realizar a segmentação é obrigatório a inserção de parâmetros que controlem o processo, a distância euclidiana e área mínima, a segmentação foi realizada a partir do método de crescimento por regiões. A avaliação de similaridade entre os pixels é feita através da distância euclidiana, ela é o parâmetro de análise do método de crescimento por regiões disponível no GeoDMA. Esse parâmetro define se dois pixels serão agregados em uma região a partir da distância que foi definida, um valor baixo significa que o algoritmo criara regiões com pouca variabilidade, enquanto que, se os valores forem altos, as regiões terão mais variabilidade no tocante ao nível de cinza.

O parâmetro chamado de área mínima define qual será a menor área que será criada, se algum objeto inicialmente for menor que o definido pelo usuário, então ele será unido com algum vizinho. Ambos os parâmetros devem ser testados a partir de combinações até que seja encontrado o melhor posicionamento da imagem. Os valores utilizados para os parâmetros da segmentação foram:

$$\text{Área Mínima} = 10$$

$$\text{Distância Euclidiana} = 20$$

4.2.2.2 Classificação por Árvore de Decisão

A extração de atributos permite que sejam obtidos vários atributos dos objetos, como as características espectrais e espaciais. A extração considera a

imagem e os objetos como dados de entrada, e assim armazenando-os no banco de dados do TerraView para uso futuro. Além disso, quando extraímos esses atributos podemos visualizar os mesmos a partir de gráficos de dispersão, onde podemos correlacionar os atributos e assim visualizar a separabilidades dos dados.

No GeoDMA, os atributos espaciais, são derivados a partir de polígonos, assim como os atributos espectrais, que podem ser combinados com informações espaciais, possuindo a nomenclatura rp. Além desses, ainda existem atributos que podem ser extraídos a partir de células, como também atributos para análises multitemporais. Para o trabalho não será necessário a utilização dos atributos tipo célula e multitemporais.

Uma vez que a etapa de extração de atributos seja realizada, são selecionadas amostras para o processo de classificação. Para realizar a classificação supervisionada é necessário que o usuário selecione amostras que representem determinadas classes presentes na imagem.

O treinamento é o processo em que as amostras são selecionadas e atribuídas a uma determinada classe definida pelo usuário, ou seja, são selecionados os objetos e associamos os mesmos as classes criadas. Foram criados quatro tipos de classes: Estradas, Solo Exposto, Vegetação e Telhados (Tabela 1). Os atributos considerados para realizar a extração foram relacionados a cor, forma, textura e além de outros atributos visuais.

Tabela 1 – Classes Definidas

Nome da Classe
Estrada
Solo Exposto
Vegetação
Telhados

Fonte: A Autora, 2020.

Realizada a etapa de treinamento, segue-se para a etapa de classificação, nela incluímos todos os atributos que foram extraídos e as amostras para a classificação. Um dos parâmetros necessários que é solicitado pelo software é para a classificação através da árvore de decisão chamado de “número mínimo de objetos por folha”. Esse parâmetro indica o limite de objetos (segmentos) que

estarão na folha para que a mesma seja compreendida como válida durante a etapa de treinamento, esse parâmetro não previne de forma direta problemas na classificação.

A partir disso, o software retorna a árvore de decisão, criada a partir de todo o processamento feito pelo usuário, dessa forma o usuário valida o modelo, e tem como entender os limites utilizados para classificação. Körting et. al. (2009), afirma que, a utilização do GeoDMA é uma vantagem para o processo de extração, normalização e armazenamento dos atributos dos dados devido a sua facilidade, e que posteriormente podem ser utilizados em outras análises.

5 DESCRIÇÃO E DISCUSSÃO DOS RESULTADOS

Neste capítulo será feita a discussão dos resultados e a análise dos principais fatores que facilitaram ou dificultaram a aplicação.

5.1 AVALIAÇÃO DO EMPILHAMENTO

A imagem IHS permitiu destacar os alvos de interesse, estradas, telhados e vegetação, quando empilhados com os índices, foi possível destacar melhor cada informação. O objetivo de realizar o empilhamento foi unir as informações da imagem IHS com os índices GRVI e VARI e assim proporcionar uma melhora na visualização dos alvos.

Abaixo é possível visualizar a Figura 11, a mesma apresenta apenas a imagem IHS visualizada nos canais RGB respectivamente, é possível perceber que a imagem destaca alvos como vegetação mais densa, caracterizada pela cor verde, o solo exposto e alguns alvos de telhado apresentam cores próximas, o que dificultaria o processo de classificação, e os alvos das estradas apresentam a cor em um tom diferente das demais, o que ajudaria a não gerar dúvida para classificar e coletar as amostras.

Figura 11 – Imagem IHS antes do empilhamento com Índices

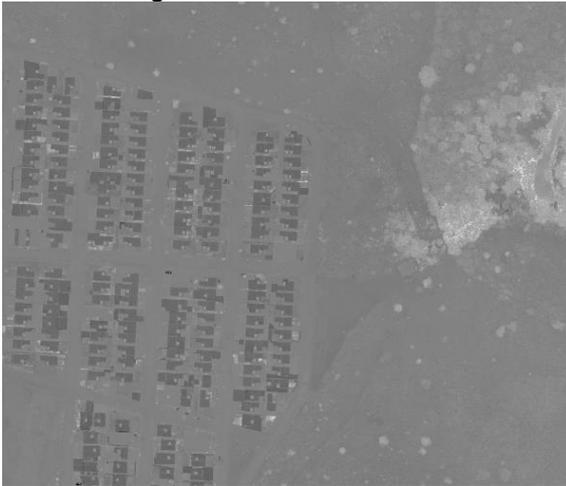


Fonte: A Autora, 2020.

Com a utilização dos índices de vegetação, foi possível destacar alvos de interesse para a classificação, em especial os telhados e a vegetação, podemos perceber o destaque da vegetação mais densa e dos telhados no índice GRVI e um pouco destaque para os telhados no índice VARI.

Segundo Silva (2020), os índices VARI e GRVI não são potenciais para a identificação da vegetação intraurbana, porém, o GRVI apresenta uma melhor identificação dos alvos como sendo cobertura edificacional, destacando para objetos do tipo telhado de cerâmica, enquanto que o VARI para o tipo telhado de cerâmica não classificou telhados ou partes de telhados com tons mais escuros.

Figura 12 – Índice GRVI



Fonte: A Autora, 2020.

Figura 13 – Índice VARI



Fonte: A Autora, 2020.

Porém quando realizado o empilhamento da imagem IHS com os índices de vegetação, é notável uma melhora na visualização e destaque dos alvos. É possível perceber que o solo exposto se caracterizou de maneira uniforme em toda a área, a vegetação mais densa localizada na região direita da imagem permaneceu destacada, e os alvos de telhados e logradouros ficaram com destaques notáveis.

Figura 14 – Imagem IHS com índices



Fonte: A Autora, 2020.

O mesmo ocorre com a imagem Original, a mesma quando empilhada com os índices apresenta uma melhora nos destaques dos alvos, principalmente na vegetação. É possível notar que alguns alvos apresentam semelhança no seu nível de cinza, logradouros e solo exposto, o que poderia dificultar o processo de classificação.

Figura 15 – Imagem Original com índices



Fonte: Autora, 2020.

5.2 AVALIAÇÃO DA VETORIZAÇÃO VS. SEGMENTAÇÃO

O processo da segmentação foi realizado utilizando os mesmos parâmetros da distância euclidiana e da área mínima para ambas as imagens, porém ainda é possível visualizar diferenças entre ambas, isso ocorre, pois, a segmentação é única para cada imagem, é possível notar as diferenças pelos casos como presença de super segmentação em alguns alvos e sub-segmentação em outros.

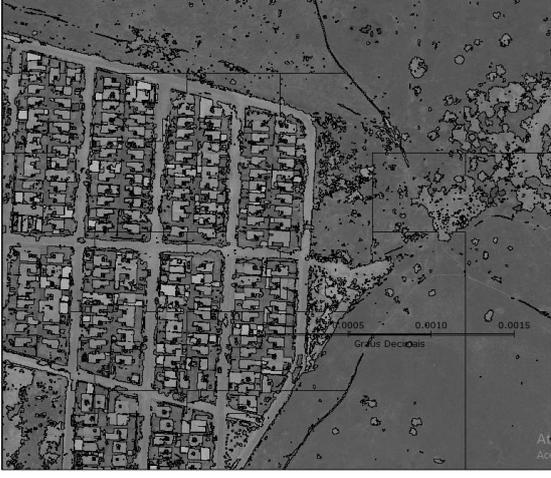
É possível notar grandes diferenças entre as segmentações obtidas entre as duas imagens, o primeiro destaque vai para a segmentação da vegetação e do solo exposto da imagem original. É possível observar que as imagens possuem diferenças nítidas em relação a essas classes quando segmentadas, tendo a primeira uma presença de super segmentação nos alvos. Vale ressaltar que a segmentação realizada por crescimento de regiões utilizou os mesmos valores de distância euclidiana e área mínima para ambas as imagens.

Os logradouros na imagem IHS não tiveram muita presença de super segmentação, enquanto que a imagem original possui mais presença de segmentos nas regiões dos logradouros. A presença de uma super segmentação pode gerar

melhorias para o trabalho, tendo em vista que, existirão mais alvos definidos e com isso a possibilidade de evitar a associação de alvos a classes a quais eles não pertencem.

É possível notar que na última imagem IHS da Tabela 2, existe um trecho da quadra que não foi bem segmentada, tendo uma abertura entre ela e o trecho de logradouro, o mesmo acontece com a imagem original, resultando em uma dificuldade de delimitar a quadra, pois o alvo não ficou bem definido pelo segmento. As três imagens apresentadas em diferentes trechos da área apresentam ocorrências de “buracos” na segmentação, principalmente nos alvos das quadras. Para os casos dos alvos que não ficaram bem definidos pelos segmentos, é provável que ocorra uma atribuição dos alvos a uma classe à qual eles não pertencem, pois ambos estão contidos no mesmo segmento.

Tabela 2 – Segmentação da Imagem Original e da Imagem IHS

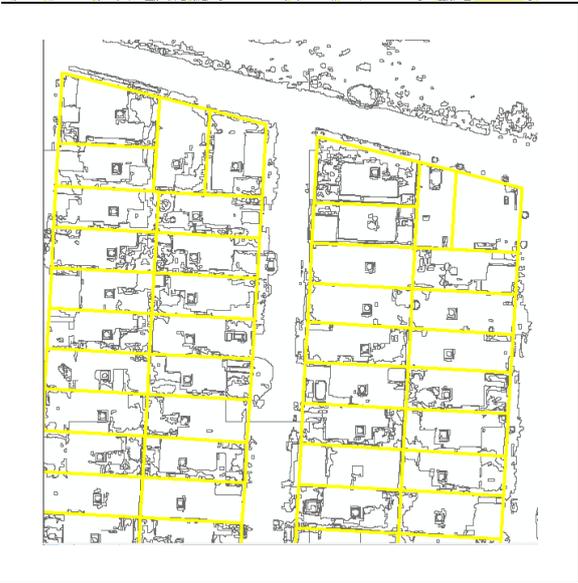
Imagem Original	Imagem IHS
	
	
	

Fonte: A Autora, 2020.

A seguir tem-se as Tabelas 3 e 4 apresentadas, a primeira procurou destacar as diferenças encontradas entre a segmentação dos lotes, que são definidos pela delimitação de telhados e estruturas ao redor do imóvel, com a vetorização manual da Compesa que segue a mesma delimitação. A segmentação apresentou presença de super-segmentação nos alvos dos lotes, é possível perceber que a sobreposição da vetorização com a segmentação apresenta a associação de alvos que foram atribuídos a um determinado segmento, porém não se enquadra no alvo de interesse.

A possibilidade para diminuição desses segmentos que não se enquadram à delimitação dos alvos seria realizar testes nos parâmetros, afim de encontrar um que se adeque melhor a proposta.

Tabela 3 – Segmentação x Vetorização (lotes)

Segmentação da Imagem Original x Vetorização dos lotes	Segmentação da Imagem IHS x Vetorização dos lotes
 This panel shows the original grayscale image of a building complex with yellow outlines overlaid. The outlines represent the segmented building footprints and the vectorized lot boundaries. The lot boundaries are a grid of yellow lines that align with the building's internal structure.	 This panel shows the same building complex as the original image, but processed using the IHS (Intensity-Hue-Saturation) color model. The yellow outlines for segmentation and lot vectorization are identical to those in the original image panel, demonstrating consistency in the results.
 This panel shows a different view of the building complex, tilted at an angle. The yellow outlines for segmentation and lot vectorization are applied to the tilted image, showing how the vectorization process adapts to the image's orientation.	 This panel shows the same tilted view of the building complex as the original image, but processed using the IHS color model. The yellow outlines for segmentation and lot vectorization are identical to those in the original image panel, showing consistent performance across different orientations.
 This panel shows the building complex rotated 90 degrees. The yellow outlines for segmentation and lot vectorization are applied to the rotated image, demonstrating the method's ability to handle non-standard orientations.	 This panel shows the same rotated view of the building complex as the original image, but processed using the IHS color model. The yellow outlines for segmentation and lot vectorization are identical to those in the original image panel, showing consistent performance across different orientations.

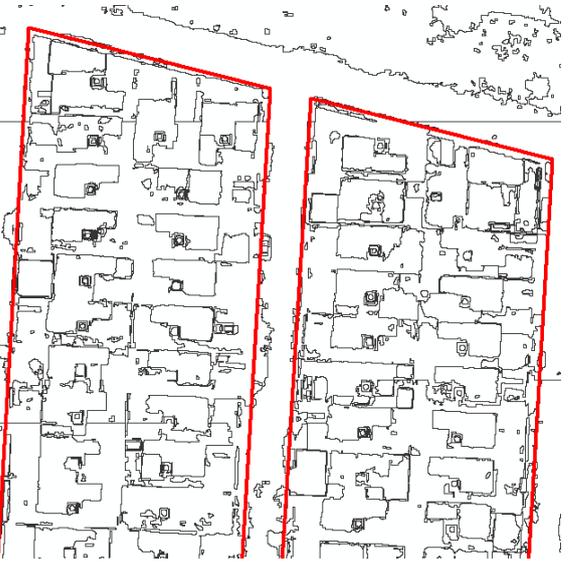
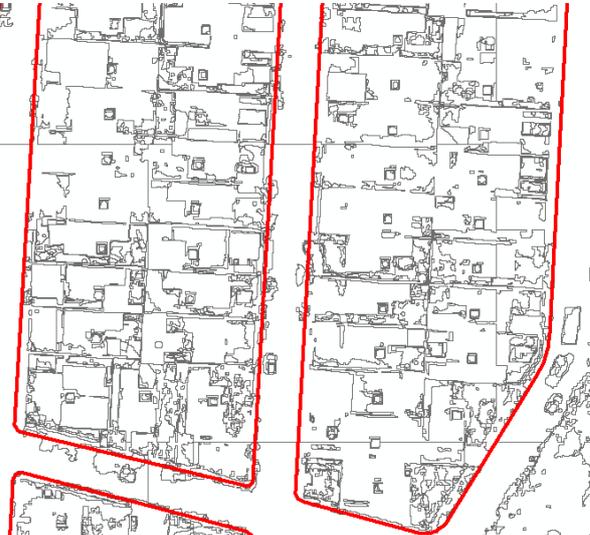
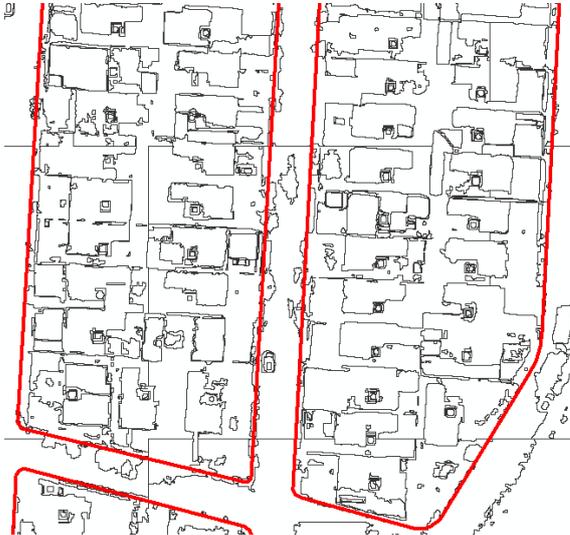
Fonte: A Autora, 2020.

A tabela 4 apresenta a comparação para as quadras, é possível perceber que houve a mesma tendência de atribuir alvos não pertencentes à classe de interesse, porém diferente do que ocorreu com os lotes, os segmentos das quadras não se enquadraram bem às vetorizações, presença de “buracos” são constantes em ambas as imagens, isso dificulta o processo de classificação, visto que no momento da atribuição, alguns alvos diferentes podem ser atribuídos a mesma classe.

Podemos notar que os alvos onde os “buracos” são recorrentes, são trechos de estradas e solo exposto, a resposta espectral dos alvos por serem semelhantes podem ter contribuído para a atribuição dos segmentos com os dois alvos, resultando em um enquadramento diferente da realidade.

É importante ressaltar que a segmentação delimitou copas de árvores que estão presentes entre os lotes, a visualização desses alvos pela imagem são pequenas, o que gera dificuldade ao usuário de nota-las, porém com a segmentação foi possível obter a delimitação desses alvos e atribuir mais amostras para a classificação.

Tabela 4 – Segmentação x Vetorização (quadras)

Segmentação da Imagem Original x Vetorização das quadras	Segmentação da Imagem IHS x Vetorização das quadras
 <p>This panel shows the original grayscale image of a street scene with two large rectangular blocks outlined in red. The image is overlaid with a complex vectorization of building outlines, showing significant noise and artifacts, particularly in the background and around the edges of the buildings.</p>	 <p>This panel shows the same street scene after IHS (Intensity-Hue-Saturation) transformation. The two large rectangular blocks are again outlined in red. The vectorization of building outlines is significantly cleaner and more accurate compared to the original image, with reduced background noise and better-defined building boundaries.</p>
 <p>This panel provides a zoomed-in view of the two large blocks from the original image. The red outlines are clearly visible. The vectorization shows a dense network of lines representing building walls, with some noise and artifacts, especially in the smaller, more complex buildings within the blocks.</p>	 <p>This panel provides a zoomed-in view of the two large blocks from the IHS image. The red outlines are clearly visible. The vectorization is much cleaner and more precise than in the original image, with well-defined building walls and minimal background noise.</p>
 <p>This panel shows another view of the original image and its vectorization. The two large blocks are outlined in red. The vectorization shows a complex network of lines representing building walls, with some noise and artifacts, particularly in the background and around the edges of the buildings.</p>	 <p>This panel shows another view of the IHS image and its vectorization. The two large blocks are outlined in red. The vectorization is significantly cleaner and more accurate compared to the original image, with reduced background noise and better-defined building boundaries.</p>

Fonte: A Autora, 2020.

5.3 AVALIAÇÃO DA CLASSIFICAÇÃO

É importante avaliar as diferenças entre a classificação da imagem original com a imagem IHS, afim de observar as diferenças entre os resultados e avaliar se houve uma melhoria para o processo de extração dos alvos e conseqüentemente sua classificação. Nas Figuras 16 e 17 é possível observar a imagem original e a imagem com a transformação IHS, ambas com empilhamento junto aos índices de vegetação, vale ressaltar que a classificação será gerada a partir de todas as camadas auxiliares inseridas em uma só imagem.

Figura 16 – Imagem Original Empilhada



Fonte: A Autora, 2020.

Figura 17 – Imagem IHS Empilhada



Fonte: A Autora, 2020.

A seguir é possível observar a quantidade de amostras coletadas para cada imagem. A imagem original é mostrada na Figura 18.

As tabelas possuem um campo intitulado de amostra de polígonos, cada quantidade está associada a uma classe, ou seja, para a tabela 5 da imagem original, a classe Estrada teve 118 amostras coletadas, onde 70 serão utilizadas para treinamento e 48 para testes, o mesmo acontece para as outras classes, Solo Exposto com 137 amostras, Telhados com 514 e Vegetação com 142 amostras. Esses valores são distribuídos pelo próprio software, buscando uma proporção de 60% para treinamento e 40% para teste da árvore de classificação.

Tabela 5 – Classes e Amostras coletadas da Imagem Original

Nome da Classe	Amostra de Polígonos
Estrada	(70/48)
Solo Exposto	(81/56)
Telhados	(310/204)
Vegetação	(85/57)

Fonte: A Autora, 2020.

A quantidade de amostras para a Imagem IHS apresentada na Tabela 6 foram, Estradas 108 amostras, Solo Exposto 138, Telhados 497 e Vegetação 129 amostras. O objetivo foi utilizar o máximo possível de quantidade de amostras iguais entre as duas imagens, porém como mencionado anteriormente, a imagem original teve mais alvos segmentados o que facilita no processo de coleta de amostras, enquanto que a imagem IHS não teve o mesmo resultado de super-segmentação

Tabela 6 – Classes e Amostras coletadas da Imagem IHS

Nome da Classe	Amostra de Polígonos
Estrada	(65/43)
Solo Exposto	(79/59)
Telhados	(298/199)
Vegetação	(77/52)

Fonte: A Autora, 2020.

Figura 18 – Imagem Original



Fonte: A Autora, 2020.

É possível observar pela Tabela 7 que as classes de Telhado em ambas as imagens ficaram visualmente bem definidas na classificação, o mesmo ocorre para a classe de Estradas. O segmento da mesma ficou bem definida, porém é possível perceber que existem alguns “buracos” na classificação, onde trechos da classe Estrada ficaram atribuídas a outras classes, como solo exposto e vegetação, é possível notar que isso ocorre com mais frequência em ambas as imagens.

A atribuição principalmente do solo exposto e da estrada em alvos com classes que não pertencem a elas, deve-se ao fato de que, no processo de segmentação, as delimitações de quadras apresentaram diversos “buracos”, tanto na imagem original, quanto na imagem IHS.

Tabela 7 – Classificação

Classificação Imagem Original	Classificação da Imagem IHS
	
	
	

Fonte: A Autora, 2020.

Como já mencionado, a etapa de segmentação pode ser uma das principais causadoras da atribuição de um alvo a uma classe à qual ela não pertence, dado que, a segmentação pode agrupar alvos diferentes ao mesmo segmento.

Uma forma de avaliar a qualidade dos resultados obtidos é por meio da matriz de confusão, Tabelas 8 e 9. A matriz correlaciona as informações dos dados verdadeiros, ou seja, um conjunto de amostras que foram utilizadas no treinamento, com os dados finais que são os classificados. A partir da matriz de confusão, foi possível analisar as melhores e piores classes classificadas, os erros de omissão (EO) que situa-se na linha da matriz de confusão e mede a acurácia da classificação e os erros de comissão (EC) situa-se na coluna da matriz de confusão que mede a confiabilidade de uma classe corresponder a verdade.

É possível analisar que a partir da Tabela 8 as classes Telhados e Vegetação obtiveram uma boa classificação, observando a diagonal da matriz a classe Telhados teve 196 amostras verdadeiramente pertencentes a classe de um total de 204, ou seja, apenas 8 amostras não foram atribuídas a ela. O mesmo ocorre na classe Vegetação, das 57 amostras e 50 foram verdadeiramente pertencentes à classe, enquanto que 7 amostras não foram atribuídas a ela.

Para analisar a acurácia da classificação, foi utilizado o cálculo para os erros de omissão, que apresentaram os valores de Estrada 35,89%, Solo Exposto de 30,76%, Telhados 4,85% e Vegetação 9,09%. Enquanto que para calcular a confiabilidade de uma classe estar corretamente classificada, foi a partir do cálculo dos erros de comissão, cada classe correspondeu ao seguinte valor, Estrada 47,92%, Solo Exposto 19,64%, Telhados 3,92% e Vegetação 12,28%.

A exatidão global pode ser calculada da seguinte maneira, a soma dos elementos da diagonal principal, que indica o total de amostras corretamente classificadas, nesse caso 291, dividida pelo número total da validação, 365. A exatidão global vai resultar em **79,72%**. Segundo Meneses et. al. (2012), a exatidão global pode variar em uma escala de 0 a 100%.

Tabela 8 – Matriz de confusão da Imagem Original

-	Estrada	Solo Exposto	Telhados	Vegetação	Total	EO %	EC %
Estrada	25	14	8	1	48	35,89	47,92
Solo Exposto	6	45	1	4	56	30,76	19,64
Telhados	7	1	196	0	204	4,85	3,92
Vegetação	1	5	1	50	57	9,09	12,28
Total	39	65	206	55	365		-

Fonte: A Autora, 2020.

Os resultados da imagem IHS são possíveis de serem observados pela Tabela 9, é possível analisar que as classes Telhados e Vegetação obtiveram uma boa classificação, observando a diagonal da matriz a classe Telhados teve 198 amostras coletadas, onde 176 verdadeiramente pertencem a classe e apenas 22 amostras não foram atribuídas, Vegetação teve 36 amostras verdadeiramente pertencentes a classe de um total de 52, ou seja, apenas 16 amostras não foram atribuídas a ela.

Para analisar a acurácia da classificação, foi utilizado o cálculo para os erros de omissão, que apresentaram os valores de Estrada 64,00%, Solo Exposto de 34,21%, Telhados 19,63% e Vegetação 48,57%. Enquanto que para calcular a confiabilidade de uma classe estar verdadeiramente classificada, foi a partir do cálculo dos erros de comissão, cada classe correspondeu ao seguinte valor, Estrada 79,07%, Solo Exposto 57,62%, Telhados 11,11% e Vegetação 30,77%.

A exatidão global foi calculada pela soma dos elementos da diagonal principal (246) dividida pelo número total da validação (352), resultando em uma exatidão global de **69,89%**.

Tabela 9 – Matriz de confusão da Imagem IHS Contrastada

-	Estrada	Solo Exposto	Telhados	Vegetação	Total	EO %	EC %
Estrada	9	2	29	3	43	64,00	79,07
Solo Exposto	0	25	8	26	59	34,21	57,62
Telhados	15	2	176	5	198	19,63	11,11
Vegetação	1	9	6	36	52	48,57	30,77
Total	25	38	219	70	352	-	-

Fonte: A Autora, 2020.

6 CONSIDERAÇÕES FINAIS

A extração de alvos em ambiente urbano é uma aplicação complexa, devido a heterogeneidade do ambiente, onde é possível ser visualizado os detalhes a partir de imagens de alta resolução, porém não são suficientes para o reconhecimento dos padrões que são utilizados para definir os limites das classes dos alvos pois existem semelhanças entre os alvos e as diferenças podem ser sutis. Portanto, o uso de imagens auxiliares ajudam a discriminar os alvos urbanos.

A COMPESA utiliza as imagens de alta resolução para extrair de maneira manual as informações dos alvos urbanos e assim gerar material cartografico para as necessidades da empresa.

O trabalho procurou estudar as contribuições possíveis do uso de imagens aéreas na faixa do visível, proveniente do PE3D, utilizando índices e transformação de imagens para a classificação do ambiente urbano. Os resultados apresentaram que: i) a transformação IHS aplicada a imagem de alta resolução, além de realçar as classes de interesse, vegetação, estradas, telhados e solo exposto, quando empilhadas manteve o resultado, apresentando uma boa visibilidade dos alvos ii) o potencial do uso dos índices VARI e GRVI para a identificação de alvos do tipo telhados, onde esses alvos foram realçados quando aplicados os índices; iii) potencial da utilização de camadas auxiliares junto as imagens para a extração das feições, gerando destaque nos alvos de interesse; iv) a classificação por árvore de decisão quando aplicada nas imagens empilhadas apresenta um potencial para discriminar as classes.

A imagem original apresentou uma facilidade para a classificação, visto que a mesma teve ocorrências de super segmentação, ou seja, um alvo foi delimitado por mais de um polígono, o que facilita o processo de treinamento, possibilitando mais coletas de amostras para o alvo de uma determinada classe, enquanto que a imagem IHS apresenta pouca segmentação dos seus alvos, o que dificulta o processo de coleta de amostras e consequentemente a classificação.

As camadas auxiliares se mostraram viáveis para a classificação do ambiente urbano, mostrando eu as imagens de alta resolução necessitam de usos de outros atributos, como índices de vegetação, para que discrimine melhor os alvos, de modo que melhore as tomadas de decisão para geração de mapeamento sobre o ambiente urbano.

Portanto, recomenda-se que seja utilizado outros tipos de camadas auxiliares como dados LiDAR para integrar os diferentes atributos e discriminar melhor os alvos com respostas espectrais semelhantes, um dos motivos é que o ambiente urbano tem uma grande variabilidade dos alvos. Outra forma seria realizar classificações dos alvos separadamente destacando a homogeneidade das quadras e lotes, como forma de pré-processamento. Visto que a COMPESA tem interesse principalmente em alvos de quadras e lotes, a segmentação precisa alcançar um nível em que seus segmentos delimitem bem os alvos.

A metodologia utilizada para ambas as imagens apresentou resultados satisfatórios, porém, é preciso realizar mais testes que possibilitem a redução de “ruídos” na etapa da segmentação e conseqüentemente uma melhor classificação de modo que evite associação de classes a qual os alvos não pertencem. A utilização dos softwares e da imagem são benéficas visto que ambas são gratuitas e não geram custos.

REFERÊNCIAS

- BASGALUPP, M. P. **LEGAL-Tree: Um algoritmo genético multi-objetivo lexicográfico para indução de árvores de decisão**. 2010. Tese (Doutorado em Ciências de Computação e Matemática Computacional) - Universidade de São Paulo, São Carlos, 2010.
- BENTO, B. M. P. **Avaliação de classificadores por árvore de decisão e árvore de regressão em cenas urbanas do sensor Wordview-2**. 2016. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016. p. 140.
- BINS, L. S. A. et. al. **Satellite Imagery Segmentation: a regions growing approach**. Anais VIII Simpósio Brasileiro de Sensoriamento Remoto. Salvador, Brasil, 14-19 abril 1996, INPE, p. 677-680.
- BLASCHKE, T. *et. al.* / **ISPRS Journal of Photogrammetry and Remote Sensing** 87 (2014). p. 180-191.
- CAMARA, G.; SOUZA, R. C. M.; FREITAS, U. M.; GARRIDO, J. Spring: Integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, Maio-Jun, 1996.
- CARVALHO, M. V. A; SILVA, G. F; CRUZ, C. B. M. Pixel individuais tratados como objetos para a classificação da cobertura da terra: integração entre geobias e mineração de dados geográficos na região metropolitana do Rio de Janeiro (RMRJ). **Revista Tamoios**, São Gonçalo (RJ), ano 14, n. 2, p. 13-24, jul-dez 2018.
- COSTA, W. S. **Segmentação de imagens de sensoriamento remoto baseada em séries temporais e DTW**. 2019. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.
- CROSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. ed. rev. Campinas: IG/Unicamp, 1992. 170p.
- D'ALGE, J. C. L. **Generalização cartográfica em sistemas de informação geográfica: aplicação aos mapas de vegetação da Amazônia Brasileira**. Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia de Transportes, São Paulo-SP, 2007.
- DURÁN, G. Y. B. N. **Estudo da resposta spectral de alvos urbanos com espectroscopia de reflectância e imagens de alta resolução espacial**. Dissertação (Mestrado Geografia e Geociências), Universidade Federal de Santa Maria, Centro de Ciências Naturais e Exatas, RS, p. 209, 2014.
- FONSECA, L. M. **Processamento digital de imagens**. Instituto Nacional de Pesquisas Espaciais (INPE), p. 105, 2000.
- GITELSON, A. A; VINA, A; ARKEBAUER, T. J; RUNDQUIST, D. C; KEYDAN, G; LEAVITT, B. Remote estimation of leaf area index and green leaf biomass in maize

canopies. **Geophysical Research Letters**, v. 30, n. 5, p.1248, 2003. doi: 10.1029/2002GL016450.

INPE. **CGOBT/INPE – Coordenação-Geral de Observação da Terra, 2019.** TerraLib/TerraView. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/projetos/terralib-terraview>. Acesso em: 07 ago. 2019.

INPE. **SER 301 – Análise Espacial de Dados Geográficos.** Softwares. Disponível em: <http://www.dpi.inpe.br/cursos/ser301/software.html>. Acesso em: 12 mai. 2020.

KORTING, T. S; FONSECA, L. M. G; ESCADA, M. I. S; CÂMARA, G. **GeoDMA – Um sistema para mineração de dados de sensoriamento remoto.** Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 7813-7820.

MENESES, P. R; ALMEIDA, T. **Introdução ao processamento de imagens de sensoriamento remoto.**

MOURA, A. C. M; CARVALHO, G. A; LAENDER, B. T; ROMEIROS, D; CASTRO, M. T; ROSSI, P. G. G; CERQUEIRA, R. **Programa Nacional de Capacitação das Cidades, Importação de arquivos Raster e Vetorial no TerraView.** Ministério da Educação -MEC.

MOURA, C. D. G; FREITAS, N. C. A; SILVA, M. P. S. **Agentes de Mineração de Imagens de Satélite.**

OLIVEIRA, R. F. **Estimativa da produtividade do algodoeiro a partir de índices de vegetação derivados de imagens orbitais de alta resolução espacial.** Dissertação (Pós-Graduação em Sensoriamento Remoto) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

PAULO, M. C. M.; MATHIAS, S. B. B. R. P; LACERDA, M; KORTING, T. S; FONSECA, L. M. G. Comparação dos atributos escolhidos pelo treinamento de classificadores de árvores de decisão com seleção de atributos por filtro. **Revista Brasileira de Cartografia**, n. XX/YY, 2012.

PINHEIRO, E. S. Imagens com alta resolução espacial: novas perspectivas para o sensoriamento remoto. **Espaço & Geografia**, v. 6, n. 1, 2003. ISSN: 1516-9375.

PLATT, R. V.; RAPOZA, L. Na evaluation of na object-oriented paradigma for land use/land cover classification. **The Professional Geographer**, v.60, p.87-100, 2008.

PRINA, B. Z; TRENTIN, R. **Geração de matriz de confusão a partir de uma classificação digital de imagem do ArcGIS.** Anais XVII Simpósio Brasileiro de Sensoriamento Remoto – SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE.

RUIZ, P. R. S. **Classificação da cobertura do solo urbano usando árvores de decisão a partir de cenas worldview-2 e worldview-3 para diferentes níveis de**

legenda. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, P. 181, 2017.

SANTOS, A. R.; PELUZIO, T. M. de O.; SAITO, N. S. (Coord). **SPRING 5.1.2 passo a passo:** aplicações práticas. Alegre, ES: Ciências Agrárias Universidade Federal do Espírito Santo/CAUFES, 2010, 155p.

SILVA, L. C. N.; BACAI, V. M. Classificação orientada a objeto (GEOBIA) aplicada a análise das alterações do uso e cobertura da terra da Bacia Hidrográfica do Rio da Prata em Jardim e Bonito -MS. **Geografia (Londrina)**, v. 26, n.1, p. 5 -18, jan/jun. 2017.

SILVA, M. L. **Classificação da cobertura do solo urbano utilizando imagens aéreas, produtos LIDAR, índices de vegetação e razão de bandas.** Dissertação (Mestrado no Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação) – Universidade Federal de Pernambuco, Recife, 2020.

WITTEN, I. H; FRANK, E; HALL, M. A. **Data mining, practical machine learning tools and techniques.** 3. ed. 2011.

WOEBBECKE, D. M; MEYER, G. E; VON BARGEN, K; MORTENSEN, D. **Plant species identification, size, and enumeration using machine vision techniques on near-binary images.** Proceedings of SPIE - The International Society for Optical Engineering. editor / James A. DeShazer ; George E. Meyer ; Boris F. Fyodorov. Vol. 1836 Publ by Int Soc for Optical Engineering, 1993. pp. 208-219.

ANEXO A – PROCESSOS DE EDIÇÃO DA COMPESA



GERÊNCIA TÉCNICA DE CADASTRO - GTC
GISCOMP

Processos de Edição por ArcGIS

Autores: Valter Vitor dos Santos
Anny Karla Gomes Dias

Recife – 2018





SUMÁRIO

1. ARCGIS	3
1.1. Conceito	3
1.2. Formatos de arquivos reconhecidos pelo ArcGIS	3
1.3. Ferramentas Básicas	8
1.3.1. Rotulo (<i>Label</i>)	8
1.3.2. Simbologia	9
1.3.3. Conversão com o banco de dados	9
1.3.4. União (<i>Join</i>)	10
1.3.5. Relação (<i>Relate</i>)	11
2. VETORIZAÇÃO	12
2.1. Logradouro	12
3. HOMOLOGAÇÃO	14





Exemplos: - Tabela GSAN

- GSAN_Integração

- MXD: arquivo que armazena o mapa, ou seja, permite visualizar todos os dados trabalhados em uma sessão específica, contendo as instruções dos dados trabalhados presentes em uma determinada pasta. Esse arquivo não possui os dados em si; caso os arquivos de dados sejam deslocados para outra pasta ou mesmos renomeados, o arquivo de mapa (.mxd) não abrirá corretamente.

Os dados geográficos são organizados segundo suas semelhanças temáticas e vêm acompanhados por uma tabela de atributos correspondentes aos dados descritivos do arquivo (dados geográficos).

Os formatos de armazenamento de dados espaciais são divididos em dois tipos: Vetorial e tipo Raster que são modos de representar o espaço por meio de estruturas geométricas.

No formato vetorial, os dados geográficos são representados por:

- Pontos : Ligação e Inscrição. Cada ponto é armazenado por um par de coordenadas (X,Y), como as Ligações, que estão ilustradas na Figura 1, e as Inscrições, na Figura 2;

Figura 1: Ligações (em verde).





Figura 2: Inscrições (em vermelho).



- Linha : Logradouro. Cada linha é armazenada por dois pares de coordenadas (X,Y). Na figura 3 estão ilustrados logradouros;

Figura 3: Logradouros (em azul).



- Polígono : Lote, Quadra, Setor Comercial, Localidade, etc. Cada polígono é um conjunto de pontos e linhas sucessivos, onde a coordenada do primeiro ponto coincide com a coordenada do último ponto. Na Figura 4 está ilustrado um polígono de Quadra, e na Figura 5, polígonos de lotes;





Figura 4: Quadra (em azul).



Figura 5: Lotes (em amarelo).



No formato *Raster*, as informações são armazenadas por matrizes ou grades formadas por células (pixel – menor elemento da imagem) de tamanho igual, e que possuem um determinado valor, cujo tamanho determina o nível de detalhamento da informação. Na Figura 6 é mostrada uma fotografia aérea de Santa Cruz do Capibaribe, na Figura 7 está ilustrada uma fotografia aérea de Azeiteiras e na Figura 8 temos uma imagem de satélite de Gravata.





Figura 6: Santa Cruz do Capibaribe – 1:1000.



Figura 7: Ameixas – 1:5000





Figura 8: Gravata – Imagem de Satélite.



1.3. Ferramentas Básicas

1.3.1 Rótulo (*Label*)

É importante a utilização dos rótulos para facilitar a identificação dos objetos no mapa.

A exibição dos campos é definida nas propriedades da camada, clicando com o botão direito, indo em "*Properties*", e em seguida na aba "*Labels*", na qual temos a opção de escolher o método, que geralmente será "*Label all the features the same way*", para rotular todos os objetos com as mesmas opções especificadas. Em "*Label field*" definimos o texto que aparecerá nos objetos, escolhendo o campo pelos atributos que aparecem na janela, ou criando uma expressão, através do botão "*Expression*".

A expressão é escrita através dos campos da camada, que podem ser escolhidos a partir de dois cliques na janela "*Fields*", junto com operações.

Para ativar/desativar os rótulos basta clicar com o botão direito na camada e habilitar ou desabilitar a opção "*Label Feature*".





1.3.2 Simbologia

A simbologia vai definir como um dado vai ser visualizado, devendo ser configurada de forma a facilitar a interpretação do dado mostrado.

Indo na camada na qual se deseja alterar a simbologia, clicar na mesma com o botão direito do mouse, e clicar em "Propriedades". Na aba "Simbologia" temos no canto direito vários tipos de configuração mostrados (*show*) por: "Features", "Categories", "Quantities", "Charts" e "Multiple Attributes".

Como possuímos simbologias padronizadas, utilizamos arquivos ".lyr" para inserir os arquivos na simbologia devemos escolher "*show*" como "Features". Clicar no botão "Import", e na janela que abrirá habilitar "Import symbology definition from a layer file", clicar no ícone com uma pasta e setar o caminho até o arquivo, como no exemplo abaixo:

||bibirajuba\arquivoscompartilhados\LYR_BASE\BaseCOMPESA\Ligação.lyr

Em "What do you want to import?" habilitar "Complete symbology definition" e clicar em "OK". Abrirá uma janela "Import symbology Matching Dialog" onde devemos selecionar os campos que serão usados para definir a simbologia importada. O "Value field" para o exemplo utilizado acima é o campo "SITCAD", então devemos escolher o atributo "Situação de Cadastro", que é o campo correspondente, e clicar em "OK". A simbologia aparecerá na aba "Simbologia" da janela "Layer Properties", devemos clicar em "Aplicar" e "OK".

1.3.3 Conexão com o banco de dados

A conexão com um banco de dados vai permitir que o usuário acesse e edite os dados disponíveis pelo mesmo. Para criar uma conexão com um banco, inicialmente devemos ter permissão para acessá-lo, sendo essa permissão concedida pelo DBA responsável.

Como exemplo vamos criar uma conexão com o banco GiscompTécnicos, para isso devemos abrir o "Catalog" e ir em "Database Connections". Em seguida, deve-se clicar em "Add Database Connection".

Irá abrir uma janela na qual "Database Platform" será "SQL Server", que é o sistema gerenciador do banco de dados. "Instance", local onde se encontra o banco, será "Goiana", e





"*Authentication Type*" poderá ser pelo usuário logado (*Operating system authentication*) ou pela autenticação do banco de dados (*Database authentication*), caso o tipo escolhido seja por operador do banco de dados, será necessário preencher os campos de usuário (*User name*) e senha (*Password*), de acordo com o "login" de rede do operador.

Em seguida serão sugeridos os bancos disponíveis na caixa "Database", devendo ser escolhido "giscompTecnicos", e "Ok".

O banco será criado como "Connection to goiana", recomenda-se renomeá-lo para GiscompTécnicos. E com dois cliques podemos abri-lo e arrastar as camadas de interesse para o Arcmap, sendo elas os *datasets* "BASE" e "BASE ADMIN", a camada "LIGACAO_JOIN" e a tabela "LOGRADOURO_GSAN".

1.3.4 União (*Join*)

O "Join" é um recurso que permite a união de dois ou mais registros vetoriais ou de tabelas, formando uma única camada.

Para explicar, vamos executar um "Join" entre a camada de ligação da Base COMPESA com a tabela do GSAN. Para isso, deve-se adicionar a tabela GSAN na "Table of contents", a tabela está localizada no banco "GiscompTecnicos" da máquina "Goiana".

Com a tabela adicionada, devemos clicar com o botão direito na camada de ligação, ir em "Join and relates" e clicar em "Join", onde abrirá a janela "Join data".

A junção da camada de ligação será por "Join attributes for a table". O campo 1 pede o atributo da camada de ligação a ser unido com a tabela, neste caso usamos o campo "Identificador de matrícula". O campo 2 pede a tabela que será ligada à camada, que será a tabela do GSAN. No campo 3 deve ser informado o atributo da tabela que será ligado a camada de ligação, que será o "IMOV_ID", lembrando de deixar a caixa de seleção "Show the attribute table of layers in this list" marcada.

Abaixo do campo 3 existem duas caixas de seleção, a primeira "Keep all records", que mantém todos os campos da camada, e a segunda "Keep only matching records", a qual deve ser selecionada, e vai manter apenas os campos da camada correspondentes a tabela. Clicando





no botão *"Validate join"*, abrirá uma janela com informações do *"Join"*, onde podemos verificar se a união será bem-sucedida, e em seguida clicar em *"OK"*.

1.3.5 Relação (*Relate*)

Essa função é semelhante ao *"Join"*, tendo como diferencial permitir ao usuário escolher qual tabela será editada ou exibida nos atributos. Um caso onde a relação de tabelas será utilizada é na edição da tabela *"LOGRADOURO_GSAN"*.

Neste exemplo, devemos ter a camada *"LIGACAO_JOIN"* e a tabela *LOGRADOURO_GSAN* na *"Table of contents"*, estando ambas localizadas no banco *"GiscompTecnicos"*. A partir de um clique com o botão direito na camada devemos escolher a opção *"Joins and Relates"* e clicar em *"Relate..."*.

Em seguida, na janela que será aberta, devemos escolher no campo 1 o atributo de ligação entre as tabelas. No campo 2 deve ser escolhida a tabela que será relacionada à camada, no caso a tabela *"LOGRADOURO_GSAN"*. O campo 3 será o atributo da tabela correspondente ao atributo escolhido no campo 1. Por fim, no campo 4 deve ser digitado um nome para identificação da tabela relacionada (*Logradouros*), e então clicar em *"OK"*.

Para editar a tabela devemos selecionar as ligações desejadas da camada *"LIGACAO_JOIN"*, em seguida ir na tabela de atributos e clicar no botão *"Related Tables"*, na parte superior da tabela, e escolher a tabela que será editada (*Logradouros*). Após escolher a tabela podemos ver que os campos selecionados na mesma são correspondentes às ligações selecionadas anteriormente na camada *"LIGACAO_JOIN"*.

Assim, com a Edição da tabela ativa e os dados desejados selecionados, podemos fazer a edição dos campos e salvar posteriormente.





2. VETORIZAÇÃO

2.1. Logradouro

Para edição dos logradouros, deve-se clicar na feição Logradouro com o botão direito em "Edit Features", e depois em "Start Editing". Em seguida, na aba "Create Features" clica-se no botão correspondente a feição Logradouro e é colocado o primeiro ponto no mapa.

O primeiro ponto deve corresponder a um extremo do logradouro, e a partir deste ir até o fim do mesmo, criando vértices e curvas quando necessário. A Figura 1 mostra como devem ser conectados os pontos iniciais, em vermelho, e os vértices, em laranja.

Figura 9: Conexão entre Logradouros



Quando o logradouro é finalizado, o mesmo apresentará cor vermelha, sendo necessário o preenchimento dos campos abaixo:

- Tipo – deve constar o tipo do logradouro, como Rua, Travessa, Avenida, Estrada, Rodovia e afins;
- Título – Será preenchido com pronomes de tratamento, geralmente antecedendo nomes de pessoas, assim como Padre, Monsenhor, Doutor, Presidente e outros.
- Nome da via – Será a palavra variável ou nomes que identificam o logradouro, como nomes de pessoas, cidades, animais ou quaisquer outro.





- Nome Completo – Será a junção dos três campos anteriores, formando o nome completo do logradouro.

A partir do preenchimento dos campos citados, o logradouro passará para a cor azul, estando assim finalizado, como mostra ainda a figura 1. Devendo também ser vetorizados logradouros onde não houver nome de rua.





3. HOMOLOGAÇÃO

Para acessar o ambiente de homologação deve-se criar uma conexão com o banco homólogo, conforme o item 1.1.3, com "*Instance*" em Goiânia e "*Database*" "homologação". O banco criado aparecerá com o nome "*Connection to goiana*", e deverá ser renomeado como "Homologacao.sde".

Abrindo o banco é possível acessar as feições a serem incluídas no MXD, para isso deve-se arrastá-las individualmente, ou pelo "*Feature Dataset*", para a "*Table of Contents*", de forma que fiquem acima da Base Compesa.

Com todas as feições na "*Table of Contents*" é possível alterar a simbologia para melhor visualizar a localização, e inserir rótulos (*labels*) para facilitar a visualização dos atributos das feições.

No caso da camada de logradouros, é possível desenhar novos e nomeá-los a partir da edição.

