

UNIVERSIDADE DE SÃO PAULO
FACULDADE DE FILOSOFIA, LETRAS E CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA

BRUNO FRUCTUOSO COELHO DE SOUZA

Paraisópolis e Heliópolis (São Paulo): abordagem da classificação GEOBIA

Paraisópolis and Heliópolis (São Paulo): GEOBIA classification approach

São Paulo

2023

BRUNO FRUCTUOSO COELHO DE SOUZA

Paraisópolis e Heliópolis (São Paulo): abordagem da classificação GEOBIA

Paraisópolis and Heliópolis (São Paulo): GEOBIA classification approach

Trabalho de Graduação Individual
apresentado ao Departamento de
Geografia da Faculdade de Filosofia,
Letras e Ciências Humanas da
Universidade de São Paulo como parte
dos requisitos para obtenção do título
de Bacharel em Geografia.

Orientador: Dr. Alfredo Pereira Queiroz

São Paulo

2023

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Catálogo na Publicação
Serviço de Biblioteca e Documentação
Faculdade de Filosofia, Letras e Ciências Humanas da Universidade de São Paulo

Sp Souza, Bruno Frutuoso Coelho de
Paraisópolis e Heliópolis (São Paulo): abordagem
da classificação GEOBIA / Bruno Frutuoso Coelho de
Souza; orientador Alfredo Pereira Queiroz - São
Paulo, 2023.
38 f.

TGI (Trabalho de Graduação Individual)- Faculdade
de Filosofia, Letras e Ciências Humanas da
Universidade de São Paulo. Departamento de Geografia.

1. GEOBIA. 2. classificação. 3. favelas. 4.
Paraisópolis. 5. Heliópolis. I. Queiroz, Alfredo
Pereira, orient. II. Título.

SOUZA, Bruno Frutuoso Coelho. **Paraisópolis e Heliópolis (São Paulo):** abordagem da classificação GEOBIA. 2023. Trabalho de Graduação Individual (TGI) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 2023.

Aprovado em:

Banca Examinadora

Prof. Dr. Alfredo Pereira Queiroz

Instituição: FFLCH – USP

Julgamento _____ Assinatura _____

Prof. Dr. _____ Instituição: _____

Julgamento _____ Assinatura: _____

Prof. Dr. _____ Instituição: _____

Julgamento _____ Assinatura: _____

Prof. Dr. _____ Instituição: _____

Julgamento _____ Assinatura: _____

RESUMO

SOUZA, Bruno Frutuoso Coelho. **Paraisópolis e Heliópolis (São Paulo):** abordagem da classificação GEOBIA. 2023. Trabalho de Graduação Individual (TGI) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 2023.

Mapear as favelas é um grande desafio para as instituições governamentais, dada a precariedade e a dinâmica desse processo de ocupação urbana. O trabalho visa classificar as favelas de Paraisópolis e Heliópolis, do município de São Paulo, por técnicas de GEOBIA. O programa eCognition e a imagem do satélite CBERS-4A, sensor WPM, com resolução pancromática de 2 metros e resolução multiespectral de 8 metros foram utilizados. Para avaliar as classificações, foi adotado o cálculo da acurácia geral da matriz de erro: Heliópolis 0,70996 e Paraisópolis 0,69022. Esses valores foram considerados bons e indicam uma concordância significativa no processo de classificação. O processo de classificação mostrou potencial para mapear as favelas, mas também ressaltou a heterogeneidade dessas ocupações precárias urbanas.

PALAVRAS-CHAVE

1. GEOBIA; 2. classificação; 3. favelas; 4. Paraisópolis; 5. Heliópolis

ABSTRACT

SOUZA, Bruno Frutuoso Coelho. **Paraisópolis and Heliópolis (São Paulo):** GEOBIA classification approach. 2023. Individual Undergraduate Work (TGI) – Faculty of Philosophy, Letters and Human Sciences, University of São Paulo, São Paulo, 2023.

Mapping favelas is a major challenge for government institutions, given the precariousness and dynamics of this urban occupation process. The work aims to classify the slums of Paraisópolis and Heliópolis, in the city of São Paulo, using GEOBIA techniques. The eCognition program and the image from the CBERS-4A satellite, WPM sensor, with a panchromatic resolution of 2 meters and a multispectral resolution of 8 meters were used. To evaluate the classifications, the calculation of overall accuracy from the error matrix was adopted: Heliópolis 0.70996 and Paraisópolis 0.69022. These values were considered good and indicate a significant agreement in the classification process. The classification process showed potential for mapping favelas, but it also highlighted the heterogeneity of these precarious urbansquatters.

KEYWORDS

1. GEOBIA; 2. classificatition; 3. slums; 4. Paraisópolis; 5. Heliópolis

LISTA DE TABELAS

Tabela 1: Características da Câmera WPM. INPE 2019.	22
Tabela 2: Número total de objetos formados por nível de segmentação.	24
Tabela 3: Árvore de classificação hierárquica das favelas, dividida nos dois níveis de segmentação das favelas.	27
Tabela 4: Média dos valores de % de Vegetação e % de Telhados de Cerâmica. ...	28
Tabela 5: Tabela de concordância entre a camada de Referência da PMSP e a Classificação gerada pelo eCognition da favela de Heliópolis.	30
Tabela 6: Tabela de concordância entre a camada de Referência da PMSP e a Classificação gerada pelo eCognition da favela de Paraisópolis.	30
Tabela 7: Matriz de erro entre a camada de Referência e a Classificação gerada pelo eCognition da favela de Heliópolis.	33
Tabela 8: Matriz de erro entre a camada de Referência e a Classificação gerada pelo eCognition da favela de Paraisópolis.	33

LISTA DE FIGURAS

Figura 1: Fluxograma da metodologia GEOBIA.	17
Figura 2: Área de estudo abordada pela pesquisa com a comparação das bases cartográficas produzidas pelo IBGE e pela Prefeitura Municipal de São Paulo.	21
Figura 3: Fluxograma da metodologia desenvolvida na pesquisa com os valores dos parâmetros de segmentação.....	23
Figura 4: Nível 1 de segmentação: (a) imagem da Favela de Paraisópolis contrastando com o seu entorno; (b) imagem após o primeiro processo de segmentação.....	23
Figura 5: Resultado da classificação do primeiro nível de segmentação.	25
Figura 6: Segundo nível de segmentação: (a) segmentação realizada com escala de 200 para identificação da Favela de Heliópolis; (b) segmentação realizada com escala de 250 para identificação da Favela de Paraisópolis.	26
Figura 7: Mapa síntese com os níveis de segmentação e classificação sobrepostos.	28
Figura 8: Comparação entre a Base Cartográfica produzida pela Prefeitura Municipal de São Paulo e a classificação produzida no eCognition.	29
Figura 9: Mapa comparativo das classes de concordância da favela de Heliópolis. .	31
Figura 10: Mapa comparativo das classes de concordância da favela de Paraisópolis.....	32

LISTA DE ABREVIATURAS E SIGLAS

BAI	Bare soil area index
CBERS	Satélite Sino-Brasileiro de Recursos Terrestres
CBERS-4A	CBERS versão 4ª
DGI	Divisão de Geração de Imagem do INPE
GEOBIA	Geographic Embased-Objects Information Analysis
GeoDMA	Geographic Data Mining Analyst
GLCM	Grey level co-occurrence matrix
GR	Green Ratio
IBGE	Instituto Brasileiro de Geografia e Estatística
INPE	Instituto Nacional de Pesquisas Espaciais
MUX	Multispectral Imager
NIR	Near Infra-red
NDRI	Normalized Difference Roof Index
NDVI	Normalized Difference Vegetation Index
PMSP	Prefeitura Municipal de São Paulo
RB	Relative border to slums
SEADE	Fundação Sistema Estadual de Análise de Dados Estatísticos
SIG	Sistema de Informações Geográficas
WFI	Wide Field Imager
WPM	Wide-sweeping Panchromatic and Multispectral Imager

SUMÁRIO

1. INTRODUÇÃO	11
2. OBJETIVOS	13
2.1. Objetivo geral	13
2.2. Objetivo específico	13
3. JUSTIFICATIVA	13
4. FUNDAMENTAÇÃO TEÓRICA	14
4.1. Conceitos de Sensoriamento Remoto	14
4.2. GEOBIA	16
4.3. GEOBIA e aplicação no meio urbano	17
5. PROCEDIMENTOS TÉCNICOS.....	18
5.1. Segmentação e classificação.....	18
5.2. Área de estudo	20
5.3. Dados da Imagem.....	21
6. METODOLOGIA.....	22
7. RESULTADOS E DISCUSSÃO	27
8. CONCLUSÕES	34
9. REFERÊNCIAS	36

1. INTRODUÇÃO

As técnicas de Sensoriamento Remoto, quando aplicadas ao estudo da ocupação urbana, são fundamentais para a obtenção de dados e reconhecimento da área urbana (RAMOS et al., 2017). O Sensoriamento Remoto, em outras palavras, simplifica a coleta de informações sobre vastas áreas e permite o “discernimento de padrões e relações não aparentes quando observadas ao nível do solo” (MACHADO, 2008). A contribuição dessas técnicas vai além da análise e monitoramento dos processos urbanos que ocorrem em São Paulo. Ela permite, também, a elaboração de políticas públicas e a criação de estratégias de desenvolvimento da cidade (RAMOS et al., 2017).

Através das técnicas de sensoriamento e SIG podem-se obter dados espaciais atualizados, detalhados do território e com alta frequência temporal, além de séries históricas de dados. Esses dados possibilitam uma visão espacial e temporal do processo de crescimento urbano e permitem obter informações deste ambiente como uso do solo, infra-estrutura, e inferir determinadas características sócio-econômicas. (ALVES, 2010, p. 190)

No estudo dos processos urbanos, o Sensoriamento Remoto é fundamental para compreender determinados padrões urbanos e as dinâmicas das cidades (ALVES, 2010). As informações obtidas pelos dados de sensoriamento remoto “têm se mostrado de grande aplicação no mapeamento de áreas urbanas e na análise e modelagem do crescimento urbano e mudanças de uso do solo” (ALVES, 2010).

O uso da Geographic Object-Based Image Analysis (GEOBIA), combinada às técnicas de sensoriamento remoto, permite o desenvolvimento de metodologias para identificação e classificação de assentamentos precários (OLIVEIRA et al., 2022). Para Blaschke (2010), a classificação a partir das técnicas de GEOBIA tem o objetivo de automatizar o processo de reconhecimento de objetos, à medida que diminui a demanda de tempo para a obtenção de informações. Contudo, a Análise de Imagens Baseada em Objetos Geográficos, segundo Blaschke (2010), depende da definição de objetos a partir da segmentação de imagens de alta resolução - “imagens cujos pixels são menores que o objeto”. Neste processo, os pixels são agrupados de acordo com suas semelhanças espectrais, texturais e geométricas e, então, são classificados por algoritmos.

O êxodo rural da população brasileira, que se deu entre os anos de 1940 e 1980, provocou uma complexa organização territorial e urbana com profundas diferenças entre as regiões (SANTOS, 2004). Em 1940, a taxa da população urbana do Brasil era de aproximadamente 26,35%, enquanto que, em 1980, a taxa aumentou para aproximadamente 68,86%. Na região Sudeste, a taxa da população que reside dentro dos centros urbanos atingiu seu maior percentual até então, aproximadamente 82,79% em 1980. Porém, mesmo tendo uma adaptação progressiva e eficiente aos interesses do capital, São Paulo ainda apresentou um grave problema no planejamento habitacional da cidade (SANTOS, 2004).

A crise habitacional que se instalou neste período, decorrente do intenso processo de urbanização, foi contornada pela omissão do poder público na expansão dos loteamentos clandestinos e autoempreendimentos de moradias populares (BONDUKI, 2004). Ainda segundo o autor, a formação das favelas em São Paulo está atrelada ao processo de expansão horizontal da malha urbana fortemente influenciada pela negligência do poder público. A autoconstrução das moradias populares localizadas na periferia da cidade, protagonizadas pela grande massa de trabalhadores de baixa renda, se tornou uma alternativa habitacional de desadensamento do grande centro e segregação sócioespacial da população trabalhadora (BONDUKI, 2004).

Para o Instituto Brasileiro de Geografia e Estatística (IBGE), a favela - também denominada de comunidade, baixada, quebrada etc. - é classificada como um Aglomerado Subnormal. Neles, residem as populações com condições socioeconômicas, de saneamento e de moradia mais precárias. Os Aglomerados Subnormais apresentam um padrão urbanístico irregular com “carência de serviços públicos essenciais e localização em áreas que apresentam restrições à ocupação” (IBGE, 2019).

Atualmente, o monitoramento e mapeamento das favelas presentes no Município de São Paulo são produtos de pesquisas de apenas duas instituições, o IBGE e a Prefeitura Municipal de São Paulo. No entanto, o intervalo de tempo entre as pesquisas é longo e distinto, de maneira que os resultados de ambas as pesquisas apresentam significativas divergências quando analisamos os tamanhos e limites das favelas.

2. OBJETIVOS

2.1. Objetivo geral

O objetivo geral da pesquisa é obter uma árvore de processos para a classificação semiautomatizada das favelas de Paraisópolis e Heliópolis, do município de São Paulo, por meio de técnicas de GEOBIA.

2.2. Objetivo específico

A pesquisa concentrou-se em três etapas fundamentais:

- A primeira etapa visou identificar atributos quantificáveis que permitiram classificação de objetos não-favelas e posteriormente das próprias favelas utilizando as imagens do satélite CBERS-4A.
- A segunda etapa consistiu na elaboração de uma árvore hierarquizada de processos com regras de segmentação e classificação.
- Na terceira etapa, foi realizada a avaliação da qualidade da classificação proposta pela pesquisa utilizando uma matriz de erro.

3. JUSTIFICATIVA

O processo informal de autoempreendimento da casa própria, segundo Bonduki (2004), não é um caso isolado quando analisamos o processo histórico de urbanização de São Paulo. Localizados em grande maioria nas periferias, os autoempreendimentos configuram-se como regiões de alta precariedade, falta de acesso à infraestrutura básica e serviços públicos essenciais. Essa dinâmica dos autoempreendimentos muitas vezes surge como resultado da combinação de diversos fatores socioeconômicos e urbanos que permearam o desenvolvimento da cidade ao longo do tempo.

As favelas de Paraisópolis e Heliópolis se destacam como as duas maiores favelas do município de São Paulo, de acordo com o IBGE. Além disso, essas duas comunidades ocupam uma posição de destaque quando comparamos com o cenário nacional, estando entre as dez favelas mais populosas do país. Tal reconhecimento atrai olhares de diversos profissionais de áreas como “arquitetura, urbanismo, sociologia, assistência social e gestão pública de todo o mundo” (CASTILHO, 2013).

Castilho (2013) destaca que Paraisópolis e Heliópolis passaram por diversas transformações relacionadas ao uso do solo ao longo do tempo, de forma que se tornaram pontos focais de estudos e pesquisas. Nesse sentido, a autora destaca a necessidade contínua de investigações nessa região, para entender e acompanhar as mudanças que ocorrem em seu ambiente.

Diante desse cenário, torna-se essencial empregar técnicas e tecnologias avançadas para identificação e mapeamento das favelas. Para Hofmann et al (2008), a elaboração de uma árvore de classificação baseada nas características ontológicas das favelas, corrobora para o monitoramento do “comportamento dinâmico dos assentamentos informais”. A abordagem sobre as favelas de Paraisópolis e Heliópolis também contribuiria para o avanço nos estudos de classificação das favelas como um todo, uma vez que permitiria a compreensão dos padrões ontológicos que constituem as favelas de São Paulo. Além disso, a aplicação de métodos de classificação para mapear as favelas adquire um significado social de grande relevância, preenchendo uma lacuna deixada pelo Estado na produção de mapas de favelas que integrem dados tanto estatísticos quanto cartográficos de maneira atualizada e detalhada (ALVES, 2010).

4. FUNDAMENTAÇÃO TEÓRICA

4.1. Conceitos de Sensoriamento Remoto

Dentre as definições encontradas na literatura científica, o Sensoriamento Remoto, em termos gerais, consiste na captação de radiação eletromagnética emitida e refletida pelas superfícies dos objetos através de sensores (MENESES, 2012). A técnica de obtenção de imagens que representam objetos da superfície terrestre exige algumas condições, segundo Meneses (2012). Dentre elas, a ausência de matéria entre o objeto e o sensor é primordial para a captação com precisão de dados que representam a realidade. Portanto, Meneses (2012) define:

Sensoriamento Remoto é uma ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres. (MENESES, 2012, p. 3)

No âmbito da aplicação, uma série de elementos exerce influência sobre a seleção do sensor mais adequado à realização do mapeamento de fenômenos

geográficos. Consequentemente, na busca por detectar e identificar objetos nas imagens, quatro tipos de resolução se destacam: resolução espacial, espectral, temporal e radiométrica, conforme destacado por Jensen (1998).

A compreensão da resolução espacial de um sensor inicialmente está vinculada ao tamanho do objeto de estudo. Essa dimensão, definida pelo pesquisador, orienta a escolha do tamanho apropriado do pixel do sensor, uma vez que o objeto de estudo deve ser "igual ou maior do que o tamanho do elemento de resolução no terreno, ou seja, da resolução espacial" (MENESES, 2012). Dentro desse contexto, Meneses (2012) define a resolução espacial como o parâmetro que estipula o tamanho mínimo de um objeto que pode ser identificado em uma imagem.

A capacidade de adquirir imagens em diversas bandas espectrais de forma simultânea representa um dos atributos mais significativos dos sensores imageadores no âmbito do sensoriamento remoto, segundo Meneses (2012). A resolução espectral abarca pelo menos três parâmetros distintos que requerem análise: o número de bandas disponíveis no sensor, determinando a diversidade de informações espectrais adquiridas; a largura das bandas em termos de comprimento de onda, influenciando a capacidade de diferenciar características específicas da superfície terrestre; e as posições das bandas no espectro eletromagnético, que definem as regiões espectrais capturadas. Esses fatores conjuntos definem a capacidade de um sensor em caracterizar e discriminar elementos na paisagem, sendo essencial para a interpretação precisa das imagens de sensoriamento remoto (MENESES, 2012).

A resolução temporal diz respeito à frequência com que o sensor realiza revisitas a uma determinada área, adquirindo imagens em intervalos regulares ao longo de sua vida operacional. Enquanto a resolução radiométrica diz respeito à capacidade do sensor de medir diferentes intensidades dos níveis de radiância, isto é, quanto "maior a capacidade do sensor, maior a resolução radiométrica" (MENESES, 2012).

Para a aplicação das técnicas de sensoriamento no meio urbano, foram selecionadas imagens que se adequassem à dificuldade que o tema da pesquisa exige. Os parâmetros de resolução espacial e espectral foram os primeiros a serem levados em conta devido sua importância para a interpretação e processamento da pesquisa. As resoluções radiométrica e temporal foram analisadas em seguida,

tendo como foco a busca por sensores com alta resolução radiométrica e com alta frequência de revisita.

4.2. GEOBIA

A Análise de Imagens Baseada em Objetos Geográficos (Geographic Object-Based Image Analysis - GEOBIA) surge como um método semiautomático crucial para a classificação de imagens obtidas por Sensoriamento Remoto (HAY; CASTILLA, 2008). Uma de suas principais vantagens reside na capacidade de gerar resultados mais significativos na categorização do uso e cobertura da terra, quando comparados com as abordagens tradicionais de classificação pixel-a-pixel (MYINT et al., 2011). Ao incorporar conhecimento espacial e contextual, a GEOBIA aprimora a precisão e a interpretação das análises.

Atribuir aos objetos de imagem um significado que seja interpretado a partir de análises em SIG, é outra característica importante de GEOBIA que Hay e Castilla (2008) destacam. Isso permite que cada objeto represente uma unidade geográfica distinta, refletindo características do mundo real de maneira mais fidedigna. Essa abordagem não apenas aumenta a precisão da classificação, mas também enriquece a interpretação dos resultados, facilitando a tomada de decisões embasadas em informações geoespaciais robustas.

Os principais pilares da abordagem GEOBIA são a segmentação e a classificação. No estágio de segmentação, a imagem é subdividida em conjuntos homogêneos de pixels, sendo a qualidade dessa segmentação um fator determinante para a eficácia da classificação subsequente. Os objetos obtidos a partir da segmentação são então classificados com base em seus atributos, que podem incluir informações multiespectrais, características geométricas, texturais ou relacionais (BLASCHKE, 2010). Esse tipo de abordagem permite uma melhor compreensão das características representadas nas imagens, levando a resultados de classificação mais ricos e relevantes. A figura 1 expressa as principais etapas do processo durante a pesquisa.

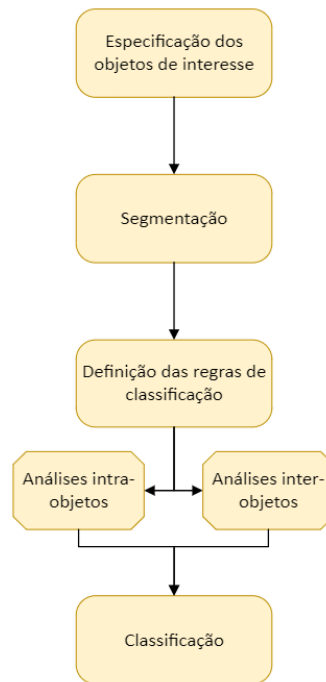


Figura 1: Fluxograma da metodologia GEOBIA.

4.3. GEOBIA e aplicação no meio urbano

Quanto à aplicação das técnicas de GEOBIA para o estudo do meio urbano, diversas literaturas e estudos serviram como base e estrutura para o desenvolvimento da metodologia desta pesquisa. O desenvolvimento de uma metodologia aplicada estritamente para o estudo das favelas é algo que se encontra mais avançado em literaturas estrangeiras, quando comparamos com pesquisas nacionais, pois a maioria dos estudos sobre o tema são produzidos por pesquisadores estrangeiros.

Dentre as bibliografias levantadas nessa pesquisa, temos o estudo elaborado por Santos et al. (2022) que propõe uma classificação de assentamentos precários baseando seu método em GEOBIA e na Análise de Mineração de Dados Geográficos (GeoDMA). Santos et al. (2022) utiliza as imagens de alta resolução provenientes do satélite CBERS-4A para a identificação de assentamentos precários em três cidades localizadas dentro do Estado do Pará: Altamira, Cametá e Marabá. O que se destaca no estudo é a utilização dos índices NDVI, NDRI e BAI para, respectivamente, classificar a presença e condição de vegetação, residências com telhados de cerâmica e áreas com solo exposto. Além disso, a combinação das

métricas de textura GLCM com os índices propostos foram fundamentais para o progresso da pesquisa.

Anteriormente à Santos et al (2022), outros autores também usufruíram de índices e métricas de textura para estudos exitosos do mesmo tema. Dentre eles, o estudo de Kohli et al (2013) discute possíveis métodos de classificação a partir da ontologia das favelas localizadas na Índia. O objetivo do estudo foi discutir maneiras de adaptar o conhecimento da ontologia das favelas locais para identificação de objetos que as representassem nas imagens do sensor GeoEye-1. Kohli et al. (2013) utiliza, portanto, das métricas de textura GLCM *Entropy* e *Contrast*, combinadas ao NDVI, à média de intensidade da banda verde, à geometria e à RB (*Relative border to slums*), para classificar objetos como vegetação, sombras, massas d'água, construções e as próprias favelas.

Em outro estudo mais recente, Kohli et al (2016) explora novamente a aplicabilidade do “uso de textura e métricas espaciais para quantificar os padrões espaciais em diferentes níveis ontológicos” da cidade de Pune (Índia). Nesse estudo, Kohli et al (2016) elaborou um método um pouco mais robusto para a classificação das favelas, onde foram realizados dois níveis de segmentação e classificação dos objetos. No primeiro nível foram identificadas as “classes básicas de cobertura do solo, como edificações e árvores”, utilizando os índices GR (*Green ratio*) e textura GLCM. No segundo nível, foi realizada uma segmentação que representasse a totalidade das favelas (KOHLI et al, 2016). O resultado da classificação se deu, segundo o autor, a partir da sobreposição dos dois níveis de segmentação e, juntamente, do cálculo da porcentagem de vegetação e porcentagem de edificações. O resultado da acurácia obtido por Kohli et al (2016) foi considerada muito boa, tendo 84,44% de precisão de classificação de favelas e 71,33% de precisão geral (média entre a acurácia de classificação de favelas e não-favelas).

5. PROCEDIMENTOS TÉCNICOS

5.1. Segmentação e classificação

A segmentação é o primeiro passo para a análise de imagem, segundo Blaschke (2010). Para Blaschke, os “segmentos são regiões geradas por um ou mais critérios de homogeneidade, em uma ou mais dimensões (de um espaço de características), respectivamente”, definindo os objetos de interesse nos

diferentes níveis e escala da imagem.

Nessa pesquisa, a segmentação foi realizada por meio da aplicação dos algoritmos: *Multiresolution Segmentation* e *Merge Region*.

O algoritmo de segmentação multirresolução agrega, consecutivamente, pixels ou imagens de objetos já existentes. Essencialmente o procedimento identifica objetos do tamanho de um único pixel e os agrega aos seus vizinhos, baseado no critério de homogeneidade relativa. Este critério de homogeneidade é uma combinação de critérios de ordem espectral e de forma. (eCognition Users guide 2018, p. 46).

A segmentação multirresolução permite a identificação de objetos a partir do critério de homogeneidade, do qual calcula “em que medida um objeto é internamente homogêneo ou heterogêneo, considerando cor e forma” (PEDRASSOLI, 2011). A ferramenta de mesclagem de regiões, por outro lado, serve para refinar os resultados de segmentação produzidos pela segmentação multirresolução. O algoritmo possibilita a mesclagem de objetos semelhantes produzidos por segmentações anteriores (eCognition Users guide 2018).

O algoritmo de mesclagem de regiões mescla todos os objetos de imagem vizinhos de uma classe para um único objeto maior. A classe a ser mesclada é especificada pelo domínio (eCognition Users guide 2018, p. 47).

Nesse sentido, o processo de segmentação das imagens é definido com base nos parâmetros de escala (*Scale*), forma (*Shape*) e compacidade (*Compactness*). O parâmetro de escala indica o nível de ação do processo do algoritmo, sendo ele um valor variável e relativo de acordo com as características de cada imagem e objetos a serem formados com a segmentação. A forma diz respeito à variação radial do objeto a ser definido e implica na influência da segmentação em comparação com a cor. Quanto maior o valor de forma, menor será a influência da cor na segmentação. A compacidade, por outro lado, “indica o grau de homogeneidade interna e heterogeneidade externa do objeto a ser definido” (PEDRASSOLI, 2011), dessa forma o valor atribuído à compacidade determinará seu peso relativo em relação à suavidade.

5.2. Área de estudo

As áreas de estudos são compostas pelas favelas de Heliópolis e Paraisópolis, localizadas nos bairros homônimos do Município de São Paulo (Figura 2). O município abrange uma área de aproximadamente 1.500 km², sendo a capital administrativa do Estado de São Paulo. De acordo com o levantamento feito pela Fundação Sistema Estadual de Análise de Dados (SEADE), em 2022, a capital possui aproximadamente 12,3 milhões de habitantes, apresentando uma densidade demográfica de cerca de 7.800 hab/km².

A Região Metropolitana de São Paulo apresenta a maior concentração de favelas do Brasil, segundo Pasternak, D'Ottaviano (2016), com 27% do total de favelas brasileiras e uma população favelada de mais de 2 milhões de pessoas. Além disso, de acordo com o Censo de 2010 produzido pelo IBGE, aproximadamente 11,40% da população total do Município de São Paulo habitava as favelas, com taxas mais altas de concentração nos setores mais periféricos do município (PASTERNAK; D'OTTAVIANO, 2016). As comunidades de Heliópolis e Paraisópolis são as duas maiores de São Paulo, tendo, respectivamente, cerca de 200 mil habitantes e área de 1,2 km² e 100 mil habitantes em uma área de aproximadamente 10 km².

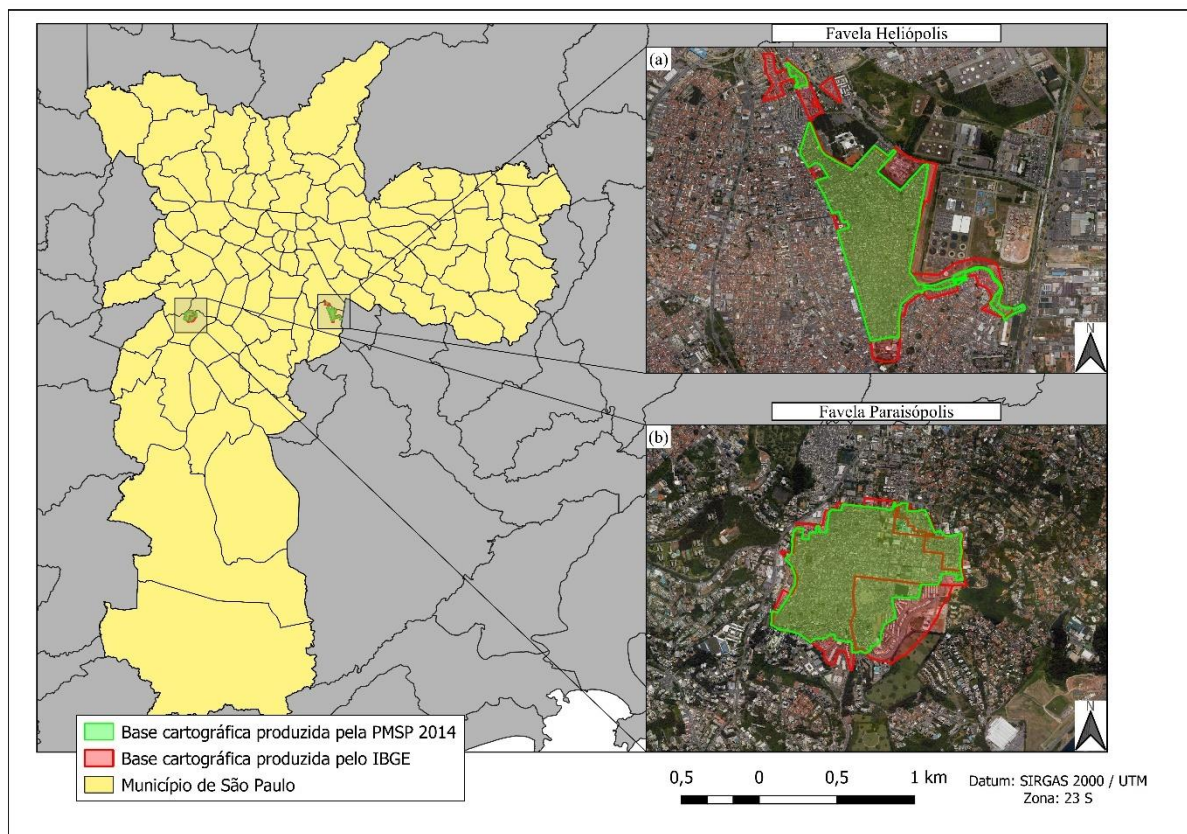


Figura 2: Área de estudo abordada pela pesquisa com a comparação das bases cartográficas produzidas pelo IBGE e pela Prefeitura Municipal de São Paulo.

5.3. Dados da Imagem

Nessa pesquisa, foram analisadas as imagens produzidas pelo satélite CBERS-4A. O Programa CBERS (China-Brazil Earth Resources Satellite) é fruto da parceria entre Brasil e China para estudos e monitoramento do território a partir de satélites próprios. O intuito dessa cooperação, visa a autonomia da produção de estudos no setor técnico-científico espacial permitindo a coleta de dados de forma independente. Suas imagens são utilizadas por instituições ligadas ao meio ambiente e recursos naturais para o controle do desmatamento e queimadas, o monitoramento de recursos hídricos, áreas agrícolas, crescimento urbano e até ocupação do solo (INPE, 2018).

O satélite CBERS-4A é equipado com três câmeras para as observações ópticas que cobrem todo o território brasileiro. São elas: a Câmera Multiespectral (MUX), com resolução espacial de 16,5 metros; a Câmera de Campo Largo (WFI), com resolução espacial de 55 metros; e a Câmera Multiespectral e Pancromática de Ampla Varredura (WPM), com resolução pancromática de 2 metros e resolução multiespectral de 8 metros (INPE, 2019).

Para uma melhor efetividade da classificação de imagens baseada em objetos geográficos, foram usadas as imagens provenientes da câmera WPM (Tabela 1), por apresentarem os seguintes atributos:

Características	Câmera WPM	
Bandas Espectrais	Imagem Pancromática (PAN)	Imagem Multiespectral
	PAN: 0,45-0,90 μm	Blue: 0,45-0,52 μm
		Green: 0,52-0,59 μm
		Red: 0,63-0,69 μm
		NIR: 0,77-0,89 μm
Resolução Espacial	2 metros	8 metros

Tabela 1: Características da Câmera WPM. INPE 2019.

As imagens foram obtidas através do site oficial do INPE, disponibilizadas pela Divisão de Geração de Imagens (DGI). A imagem selecionada é de 03 de setembro de 2020 (path: 202, row: 143).

Os softwares utilizados foram:

- QGIS: para empilhamento e composição colorida das imagens, fusão das imagens Multiespectrais de 8 metros com as imagens Pancromáticas de 2 metros, recorte e extração de mapas temáticos.
- eCognition: para segmentação de multirresolução, para testes dos atributos quantificáveis e classificação dos objetos.

Inicialmente, as imagens foram importadas para o software QGIS e empilhadas através da composição de imagens, de forma que as bandas RGB e NIR (infravermelho) foram sobrepostas, resultando em uma única imagem colorida. Posteriormente, foi feita a fusão das imagens pancromáticas com as imagens Multiespectrais, com intuito de aumentar a resolução espectral de 8 para 2 metros. No software eCognition, as imagens passaram para a etapa seguinte de especificação da área de estudo, segmentação, definição das regras de classificação e, por fim, classificação das favelas.

6. METODOLOGIA

No estudo, a metodologia desenvolvida levou em conta uma análise baseada em dois níveis de segmentação e classificação, assim como foi abordado nas

literaturas expostas nessa pesquisa. O emprego de uma abordagem multinível permitiu uma identificação mais precisa das favelas Paraisópolis e Heliópolis utilizando as imagens CBERS-4A de 2 metros de resolução. A Figura 3 constitui no fluxograma que resume a metodologia construída na pesquisa.

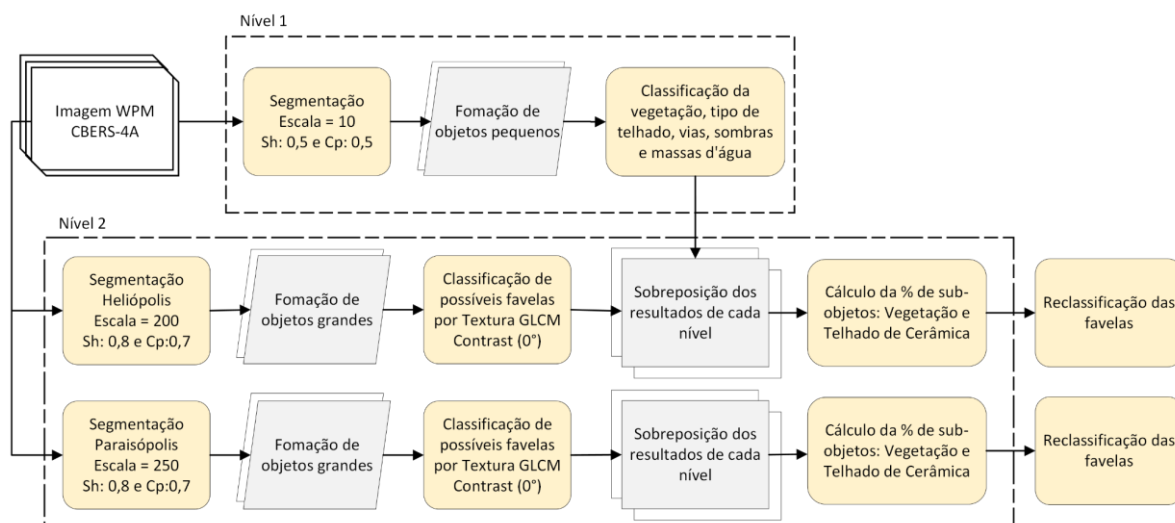


Figura 3: Fluxograma da metodologia desenvolvida na pesquisa com os valores dos parâmetros de segmentação.

As imagens foram divididas em dois níveis de segmentação, seguindo os parâmetros expostos pela Figura 3. Os dois algoritmos (*Multiresolution Segmentation* e *Merge Region*) foram usados de forma que possibilitaram uma melhor classificação dos objetos, sendo o Nível 1 uma segmentação base e o Nível 2 a segmentação propriamente das favelas. No nível 1, o valor utilizado para a escala foi 10, enquanto os parâmetros de Shape e Compactness receberam, respectivamente, os valores de 0,5 e 0,5. É possível visualizar o resultado do primeiro nível de segmentação na Figura 4.

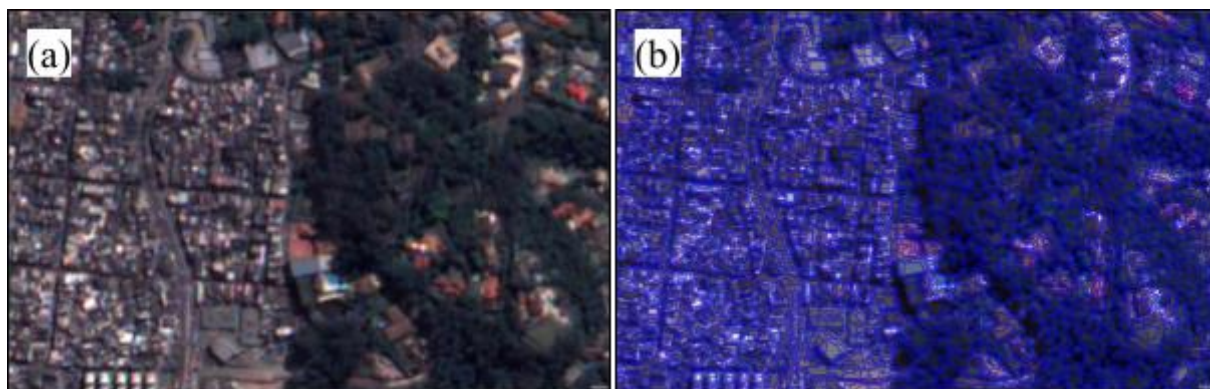


Figura 4: Nível 1 de segmentação: (a) imagem da Favela de Paraisópolis contrastando com o seu entorno; (b) imagem após o primeiro processo de segmentação.

Nesse nível, portanto, temos a formação de objetos pequenos que

permitem a identificação e classificação dos pixels que representam a vegetação, tipo de telhado, vias, massas d'água e sombras. O intuito dessa segmentação é identificar todos os objetos da imagem, por menores que sejam, e evitar qualquer tipo de generalização. Para Hofmann et al (2008), o primeiro nível de segmentação é essencial para identificar objetos que representam características da ontologia das favelas. Nesse sentido, os objetos frutos do nível inicial de segmentação são denominados de sub-objetos.

Quanto à quantidade de objetos, no nível base foram formados um total de 5.201.200 objetos (Tabela 2), dos quais a grande maioria recebeu algum tipo de classificação. É possível visualizar uma amostra do resultado dessa primeira seleção na Figura 5.

Nível 1 de Segmentação		
Número de objetos	5.201.200	
Nível 2 de Segmentação		
Favelas	Paraisópolis	Heliópolis
Número de objetos	2.950	5.404

Tabela 2: Número total de objetos formados por nível de segmentação.

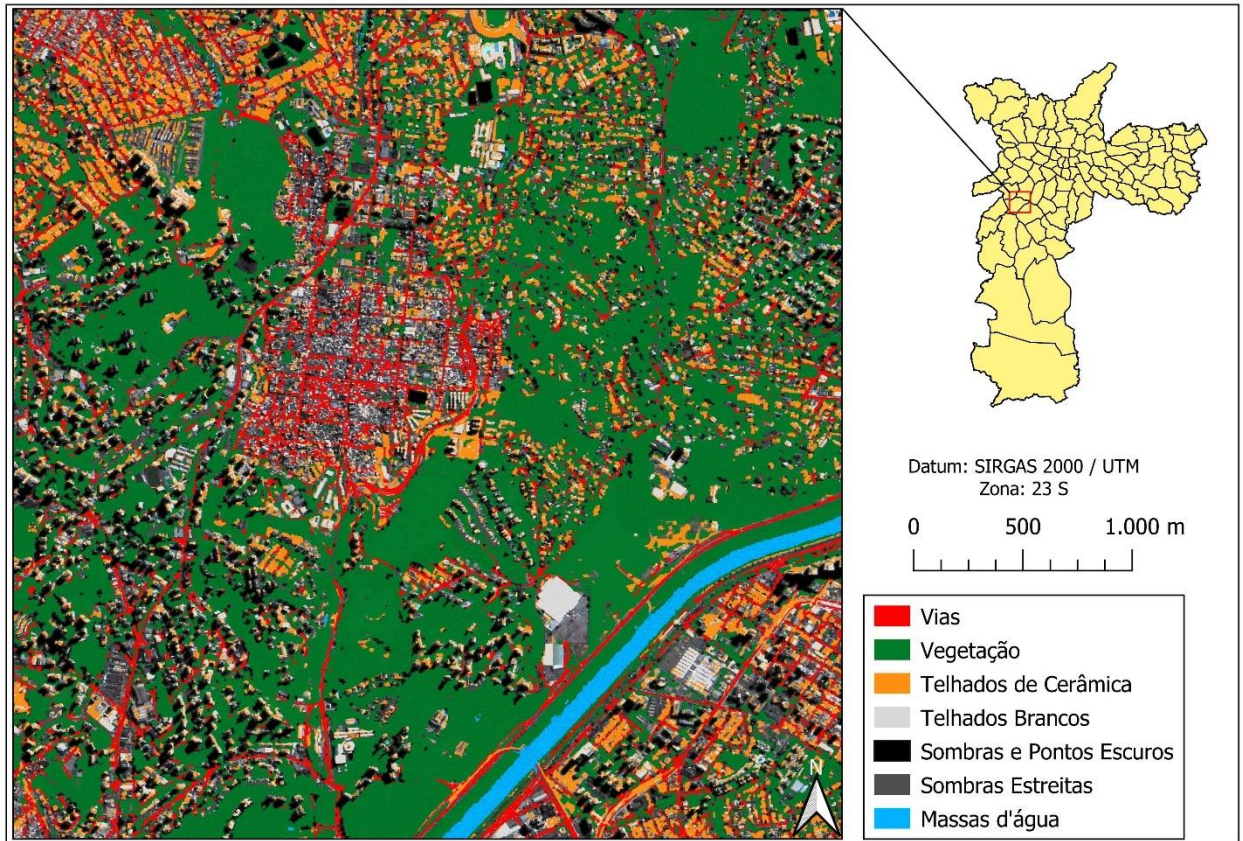


Figura 5: Resultado da classificação do primeiro nível de segmentação.

Nessa etapa, os objetos que representavam vias e massas d'água foram classificados através de mapas temáticos digitalizados. A utilização de mapas temáticos auxiliou na extração de objetos de imagem já conhecidos que poderiam atrapalhar na interpretação do software. Para a classificação dos telhados brancos, sombras e pontos escuros foram utilizados diferentes valores de *Brightness*.

Com relação à classificação da vegetação e de casas com telhados de cerâmica, foram utilizados diferentes valores dos índices NDVI e NDRI.

- *Normalized Difference Vegetation Index* (NDVI): índice utilizado para analisar presença e condição da vegetação (SANTOS et al, 2022). Consiste na divisão normalizada da banda infra-vermelho próximo pela banda vermelha.

$$NDVI = (NIR - RED) / (NIR + RED)$$

- *Normalized Difference Roof Index* (NDRI): índice utilizado para identificar telhados de cerâmica e solo exposto (SANTOS et al, 2022). Consiste na divisão normalizada da banda vermelha próximo pela banda azul.

$$NDRI = (RED - BLUE) / (RED + BLUE)$$

No nível dois, foram feitas duas segmentações diferentes para as favelas de Heliópolis e Paraisópolis, obedecendo os mesmos parâmetros de *Shape* e *Compactness*, porém com valores de escala distintos. Os valores de *Shape* e *Compactness* utilizados para o melhor recorte da imagem foram, respectivamente, de 0,8 e 0,7. O parâmetro de escala, no entanto, foi diferente para os dois objetos de estudo, pois as duas favelas apresentam características espectrais e de forma discrepantes quando analisadas pelas imagens do satélite CBERS-4A. Para a favela de Heliópolis, o valor de escala utilizado foi 200, enquanto, para Paraisópolis, o valor utilizado foi 250. É possível visualizar o resultado do segundo nível de segmentação na Figura 6.

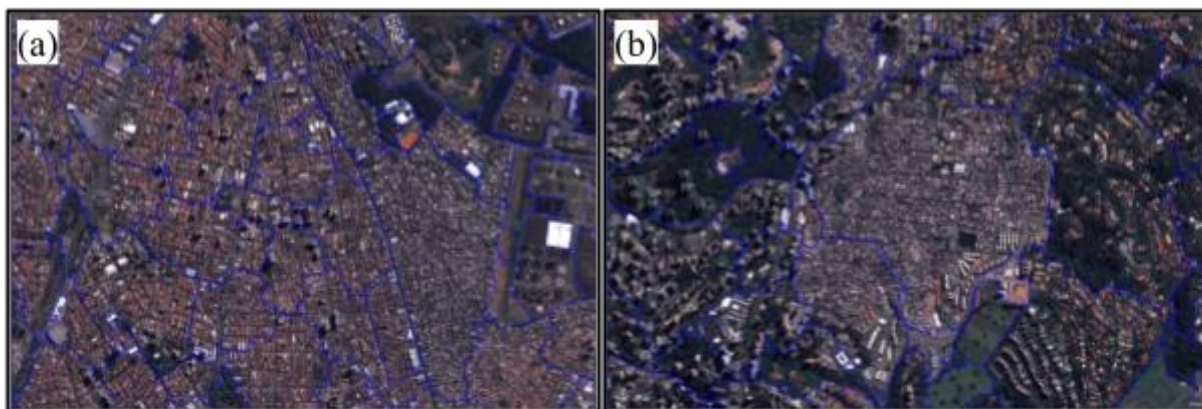


Figura 6: Segundo nível de segmentação: (a) segmentação realizada com escala de 200 para identificação da Favela de Heliópolis; (b) segmentação realizada com escala de 250 para identificação da Favela de Paraisópolis.

A segmentação realizada no segundo nível produziu objetos muito maiores do que a segmentação do nível anterior, uma vez que o objetivo desse recorte foi criar objetos que incorporassem integralmente as favelas com a menor quantidade de segmentos. Ao todo, no nível 2 foram formados para a identificação da Favela de Heliópolis (a) e Paraisópolis (b), respectivamente, 5.404 e 2.950 objetos (Tabela 2). Após obter um resultado satisfatório, os primeiros atributos usados para a identificação de possíveis objetos que representavam as favelas de Heliópolis e Paraisópolis foram: Textura GLCM Contrast (0°) e a Área (pxl). Em seguida, houve a sobreposição dos resultados dos níveis 1 e 2 de segmentação, como exposto na Figura 3, para calcular a porcentagem de sub-objetos presentes no interior dos segmentos produzidos no nível dois. Daí em diante, os segmentos que possuíam menor porcentagem de casas com telhados de cerâmica e vegetação foram classificados como favelas.

A Tabela 3 apresenta a árvore de classificação hierárquica das favelas com os respectivos valores dos atributos quantificáveis. As duas favelas obedecem a mesma estrutura hierarquizada de segmentação e classificação, porém com escala e intervalo dos valores distintos. Para Heliópolis, os objetos que possuíam valores de Textura GLCM Contrast (0°) entre 499 e 537, com áreas menores ou iguais a 23200 pixels, com % de Vegetação entre 1,01 e 3,969 e % de Telhados de Cerâmica entre 1,03 e 1,65, foram classificados como favela. A Favela de Paraisópolis, por outro lado, foi definida pelos objetos cujos valores de Textura GLCM Contrast (0°) fossem entre 379 e 432, com áreas menores ou iguais a 217000 pixels, com % de Vegetação entre 7,8 e 14 e com % de Telhado de Cerâmica entre 8,18 e 8,97.

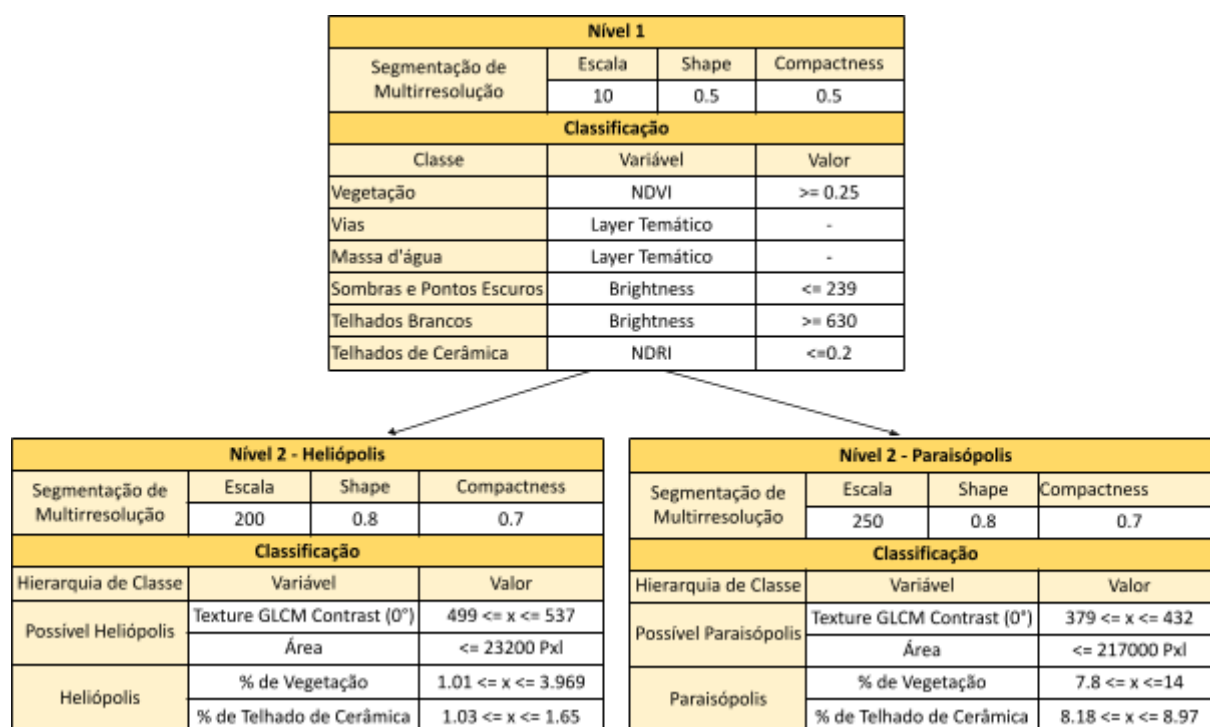


Tabela 3: Árvore de classificação hierárquica das favelas, dividida nos dois níveis de segmentação das favelas.

7. RESULTADOS E DISCUSSÃO

A Figura 7 mostra o mapa síntese dos níveis de segmentação e classificação das favelas sobrepostos. As classes de uso da terra foram extraídas na primeira segmentação (nível 1 da Tabela 3) e o limite das favelas (cor amarela) foi obtido na segunda segmentação (nível 2). Observa-se que no interior dos limites classificados como favelas, existe baixa concentração de objetos classificados como vegetação e

telhados de cerâmica, enquanto nas regiões ao entorno a presença desses objetos é abundante.

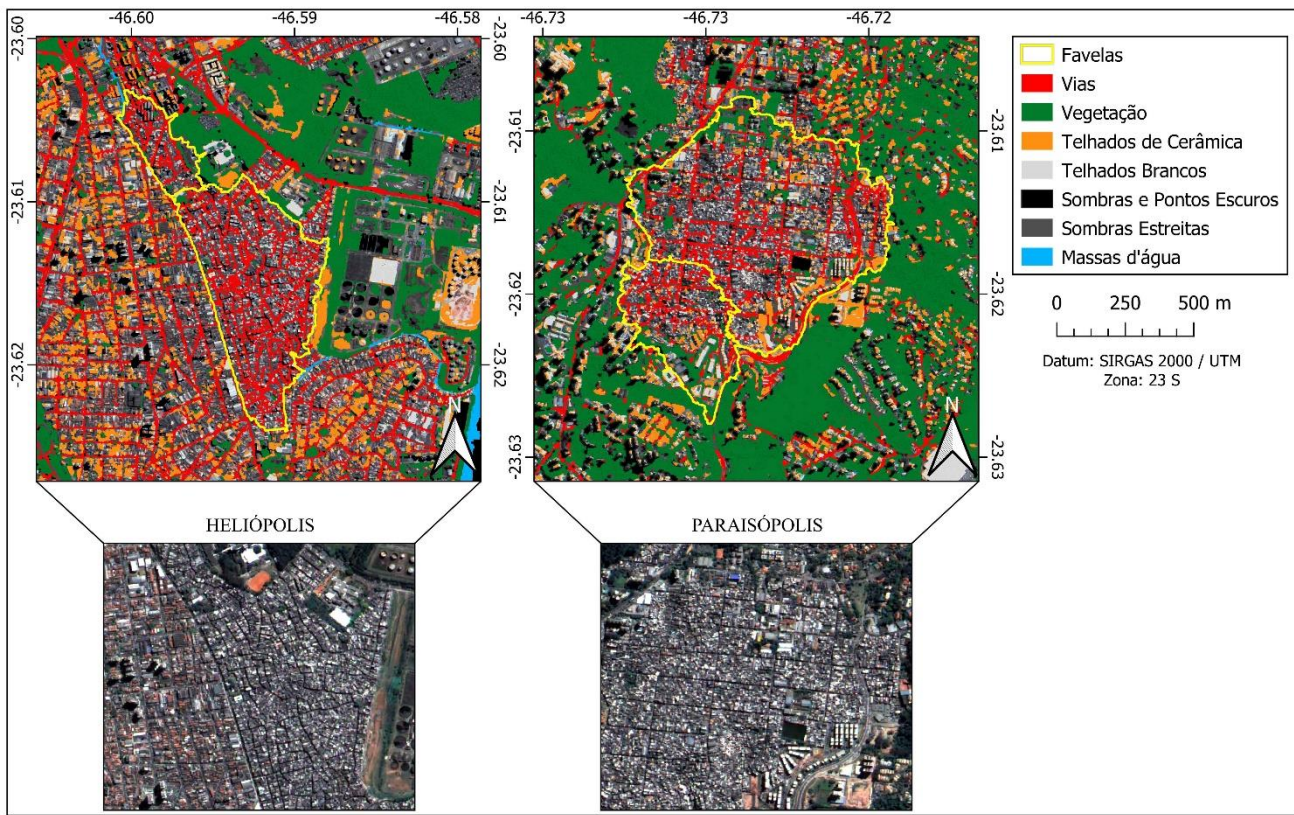


Figura 7: Mapa síntese com os níveis de segmentação e classificação sobrepostos.

A Tabela 4 apresenta a média dos valores de % de Vegetação e de Telhados de Cerâmica presentes nos segmentos adjacentes aos segmentos classificados como favelas e a média desses valores nas próprias favelas, levando em conta as diferentes escalas atribuídas para as segmentações.

Paraisópolis (Escala: 250)			Heliópolis (Escala: 200)	
	% de Vegetação	% de Telhados de Cerâmica	% de Vegetação	% de Telhados de Cerâmica
Média nas favelas	10,936	8,575	2,529	1,8595
Média no interior dos segmentos adjacentes	50,918	10,208	9,3596	14,542

Tabela 4: Média dos valores de % de Vegetação e % de Telhados de Cerâmica.

Os segmentos classificados como Paraisópolis tiveram uma média de Vegetação de 10,936% e de Telhados de Cerâmica de 8,575%, enquanto os segmentos que representam as áreas de não favelas situadas nas proximidades de

Paraisópolis, tiveram uma média de Vegetação de 50,918% e de Telhados de Cerâmica de 10,208. Em Heliópolis, as médias de % de Vegetação e de % de Telhados de Cerâmica presentes nos interiores dos segmentos foram, respectivamente, 2,529 e 1,8595. Enquanto os segmentos de não favelas do seu entorno tiveram valores de 9,3596 e 14,542 para % de Vegetação e % de telhados de Cerâmica. Os valores registrados na Tabela 4, portanto, reforçam o entendimento de que há uma diferença substancial na presença destes objetos específicos entre as áreas consideradas como não favelas e aquelas classificadas como favelas.

Nesse sentido, quando analisamos o emprego de técnicas de Análise de Imagens Baseada em Objetos Geográficos (GEOBIA), a identificação e classificação dos elementos Telhados de Cerâmica e Vegetação ocupam um papel crucial para a classificação final das favelas de Paraisópolis e Heliópolis. A Figura 8 demonstra a comparação entre o resultado dessa classificação e a base cartográfica das favelas produzida pela Prefeitura Municipal de São Paulo. Nota-se que o processo foi mais eficiente na favela de Heliópolis, pois a concordância entre as áreas foi maior (PMSP e eCognition), quando comparado com a classificação de Paraisópolis, na qual os limites obtidos na classificação foram expandidos praticamente em todo o perímetro da favela.

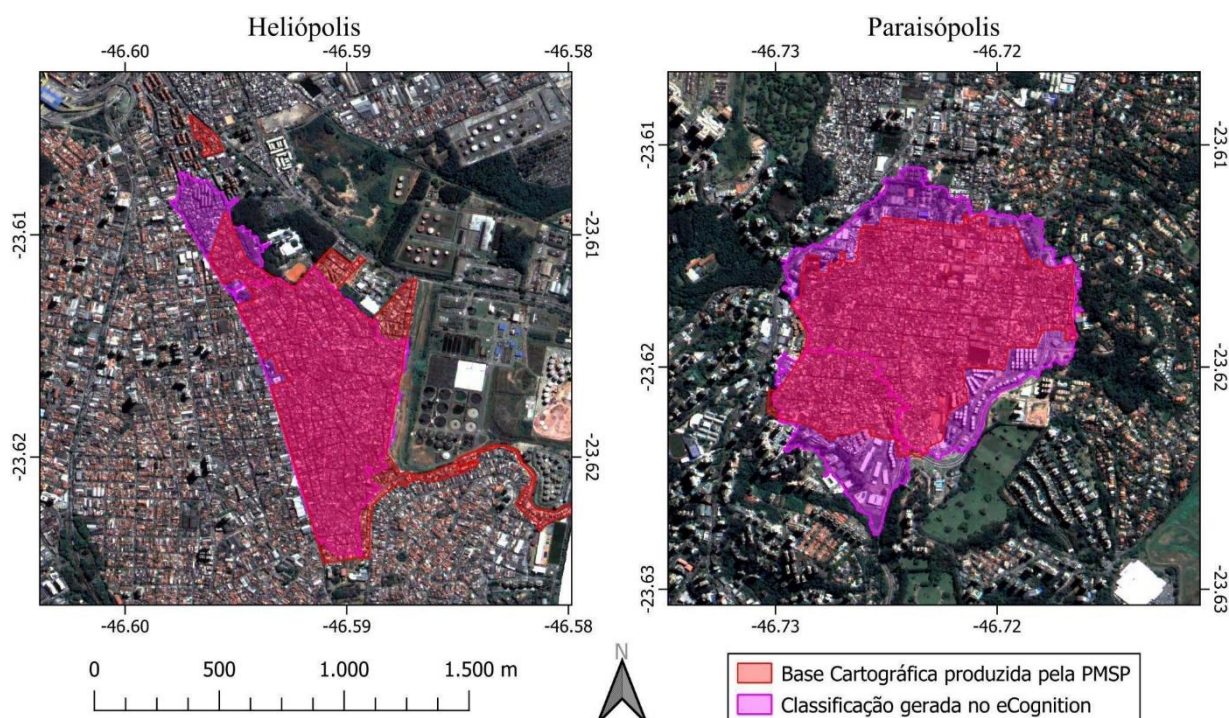


Figura 8: Comparação entre a Base Cartográfica produzida pela Prefeitura Municipal de São Paulo e a classificação produzida no eCognition.

Para efeito de avaliação da classificação, foi calculada a matriz de erro utilizando como referência a Base Cartográfica PMSP para as duas favelas. A acurácia geral, calculada a partir da matriz de erro, foi utilizada como indicador quantitativo do desempenho da metodologia desenvolvida. As Tabelas 5 e 6 apresentam a concordância e discordância dos pixels entre as camadas das favelas de Heliópolis e Paraisópolis com a camada de referência da PMSP. O resultado, portanto, foi dividido em três classes de concordância ou discordância que estão ilustradas nas Figuras 9 e 10.

Classes	Referência PMSP	Classificação eCognition	Total de Pixels
1	Favela	Não favela	20149
2	Não favela	Favela	29129
3	Favela	Favela	120625

Tabela 5: Tabela de concordância entre a camada de Referência da PMSP e a Classificação gerada pelo eCognition da favela de Heliópolis.

Classes	Referência PMSP	Classificação eCognition	Total de Pixels
1	Favela	Não favela	2130
2	Não favela	Favela	85339
3	Favela	Favela	194892

Tabela 6: Tabela de concordância entre a camada de Referência da PMSP e a Classificação gerada pelo eCognition da favela de Paraisópolis.

A classe 1 consiste na região da camada de referência classificada como favela, mas que foi classificada como não favela pelo método da pesquisa. Para Heliópolis temos um total de 20149 pixels e para Paraisópolis temos um total de 2130 pixels. A classe 2, no entanto, consiste na região da camada de referência que não foi classificada como favela, mas que foi classificada como favela pelo método da pesquisa. Em Heliópolis temos um total de 29129 pixels e Paraisópolis temos um total de 85339 pixels. Para efeito de avaliação, os pixels das classes 1 e 2 foram considerados como erro da classificação, uma vez que traduzem uma relação de

discordância entre as duas camadas. A região excendente da camada de referência que não foi identificada pelo método da pesquisa e a região excendente da classificação da pesquisa que não consta na camada de referência, somadas, representam o erro total da classificação gerada.

A classe 3, portanto, consiste na região de concordância entre as duas camadas, ou seja, a região cuja a classificação da pesquisa foi a mesma da camada de referência. Temos um total de 120625 pixels na classificação da favela de Heliópolis e 194892 pixels na classificação da favela de Paraisópolis.

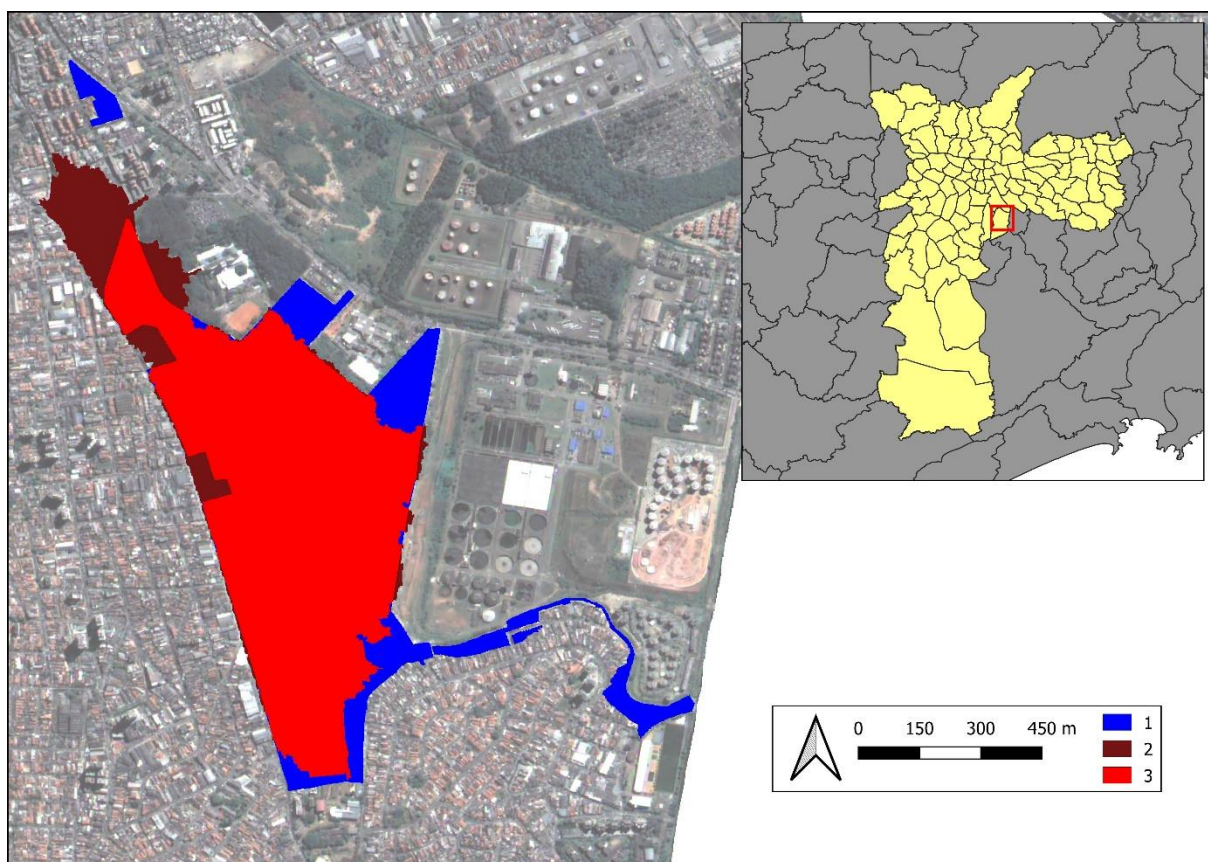


Figura 9: Mapa comparativo das classes de concordância da favela de Heliópolis.

A Figura 9 ilustra o resultado da concordância entre as duas camadas da favela de Heliópolis. Observa-se que o método da pesquisa apresentou uma significativa dificuldade para classificar as regiões mais estreitas localizadas nas extremidades da camada de referência, enquanto que a região de concordância concentrou-se na região central. Esse resultado se deu por conta da escala utilizada para a segmentação e por conta da resolução da imagem utilizada. Devido ao tamanho da favela de Heliópolis, foi necessário utilizar uma escala de segmentação que abrangesse a totalidade de sua área, porém esse efeito, consequentemente, causou uma perda de detalhes que compõem a favela. Portanto, áreas

especificamente mais estreitas e menores, acabam não sendo identificadas no recorte na etapa de segmentação.

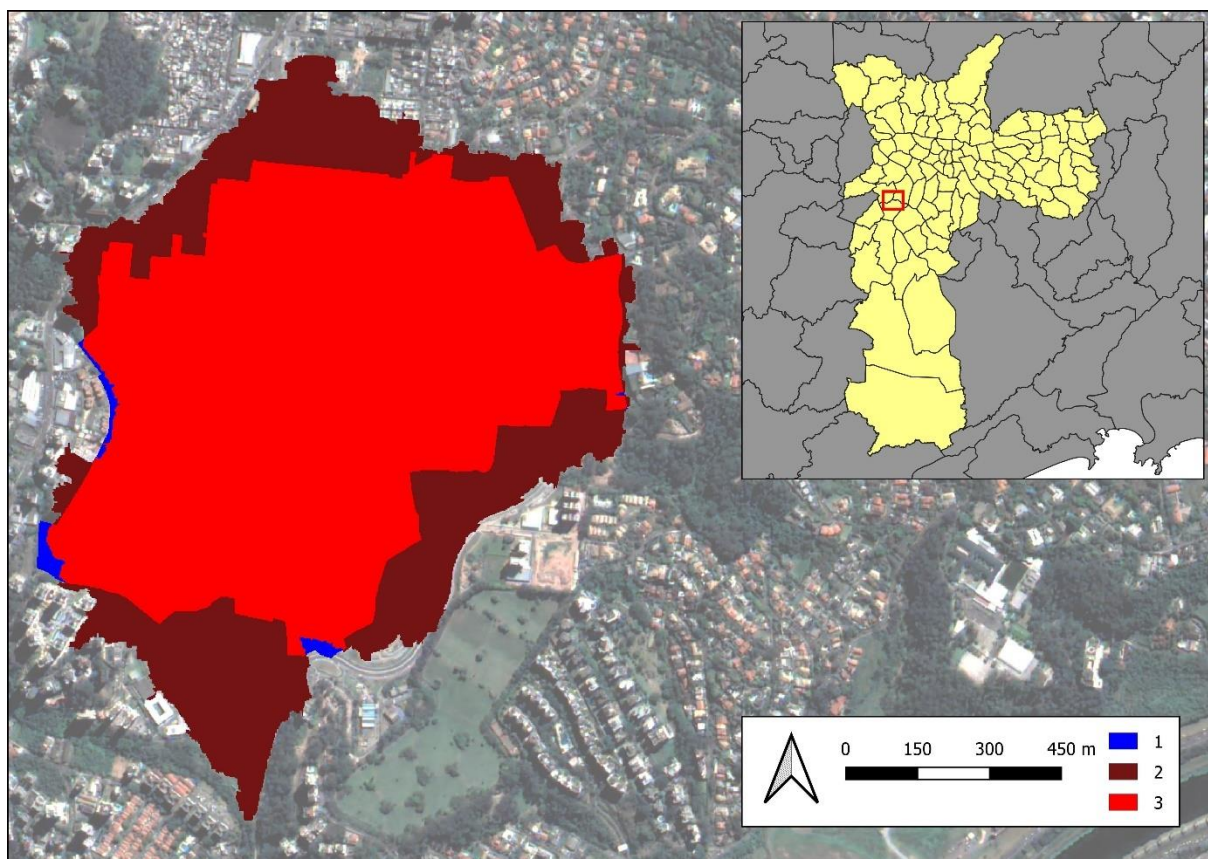


Figura 10: Mapa comparativo das classes de concordância da favela de Paraisópolis.

A Figura 10 ilustra o resultado da concordância entre as duas camadas da favela de Paraisópolis. Observa-se que, diferentemente da classificação de Heliópolis, Paraisópolis se destaca por apresentar uma região excedente classificada como favela pelo método da pesquisa (Classe 2). Esse resultado surgiu por conta da generalização interpretada pelo software no segundo nível de segmentação. Da mesma maneira que para Heliópolis foi utilizado um valor de escala elevado, para Paraisópolis a escala foi utilizada com o mesmo objetivo de abranger a totalidade da favela, consequentemente, o software não foi capaz de distinguir algumas regiões de não favela que possuíam características espectralmente semelhantes à favela.

A acurácia da classificação foi calculada a partir das matrizes de erro expostas nas Tabelas 7 e 8 da pesquisa. Para o cálculo final da acurácia, os valores de pixels de Não favela das duas camadas foram desconsiderados, visto que esses

valores simbolizam falsos-positivos e poderiam comprometer cálculo da acurácia geral.

O valor da acurácia geral foi calculado a partir da divisão entre o valor de concordância dos pixels das duas camadas com o total de pixels gerados, ou seja, o valor de pixels representados pela Classe 3 de concordância dividido pela soma total das três classes de concordância.

		Classificação eCognition		
		Não favela	Favela	Total
Referência PMSP	Não favela	-	29129	29129
	Favela	20149	120625	140774
	Total	20149	149754	169903

Tabela 7: Matriz de erro entre a camada de Referência e a Classificação gerada pelo eCognition da favela de Heliópolis.

		Classificação eCognition		
		Não favela	Favela	Total
Referência PMSP	Não favela	-	85339	85339
	Favela	2130	194892	197022
	Total	2130	280231	282361

Tabela 8: Matriz de erro entre a camada de Referência e a Classificação gerada pelo eCognition da favela de Paraisópolis.

Para Heliópolis foi atingido o valor de 0,70996 de acurácia geral da classificação gerada pela metodologia da pesquisa, enquanto para Paraisópolis foi atingido o valor de 0,69022 de acurácia geral. Observa-se que a classificação de Paraisópolis obteve maior quantidade de pixels em concordância com a camada de referência quando comparamos com a classificação de Heliópolis. Porém, proporcionalmente, gerou mais pixels em discordância do que a classificação gerada para Heliópolis. Por conta disso o valor de acurácia geral da classificação de Paraisópolis foi inferior a acurácia geral da classificação de Heliópolis.

8. CONCLUSÕES

Em síntese, este estudo visa contribuir significativamente na aplicação da Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) para a classificação semiautomatizada das favelas de Paraisópolis e Heliópolis, no contexto urbano do município de São Paulo. Ao considerar os principais atributos quantificáveis, surge um notável progresso na compreensão das características ontológicas que distinguem esses ambientes urbanos informais. Para Kohli et al (2013), compreender a ontologia genérica da favela é o que fornece uma “descrição abrangente das características espaciais e suas relações para representar e caracterizar favelas a partir de uma imagem.”

Destaca-se, especialmente, a identificação dos atributos principais que conduziram à classificação das favelas de Paraisópolis e Heliópolis. A inclusão de métricas de textura GLCM *Contrast*, juntamente com as porcentagens de Vegetação e Telhados de Cerâmica, demonstra efetividade na compreensão da complexidade e heterogeneidade das áreas estudadas. Esses atributos quantificáveis desempenharam um papel fundamental ao permitir uma análise detalhada das características espectrais, espaciais e texturais das favelas, tornando possível a diferenciação precisa entre as áreas de interesse e as áreas não-favelas.

Outro ponto crucial deste estudo está na adaptação das técnicas convencionais de GEOBIA para a realidade específica das favelas. A utilização do método com diferentes níveis de análise solucionou um problema encontrado no início da pesquisa. O meio urbano, diferentemente das paisagens rurais, apresenta inúmeras variáveis visuais que atrapalham a interpretação do software e do pesquisador. Porém, quando separamos os níveis de análise, conseguimos também diminuir a complexidade dela, de modo que, com pequenas modificações na escala e dos intervalos das variáveis na árvore de classificação, conseguimos um resultado significativo para imagens com 2 metros de resolução.

Além disso, os resultados obtidos, superiores a 65% nos valores de acurácia geral, são considerados bons dentro da metodologia proposta. A concordância entre as classificações automáticas e os dados de referência da Prefeitura do Município de São Paulo corroboram para um incentivo ao estudo de novas metodologias que partam da abordagem GEOBIA para estudar o meio urbano. Em suma, este estudo representa não só uma tentativa de avanço na adaptação das técnicas de GEOBIA

para a análise e contextualizada de favelas do município de São Paulo, mas também uma tentativa de auxiliar pesquisadores e o poder público no avanço do mapeamento de favelas e das desigualdades contidas na cidade.

9. REFERÊNCIAS

ALVES, C. D.; FLORENZANO, T. G.; PEREIRA, M. N. **Mapeamento de áreas urbanizadas com imagens Landsat e classificação baseada em objeto**. Revista Brasileira de Cartografia, [S. l.], v. 62, n. 2, 2011.

BONDUKI, Nabil. **Origens da habitação social no Brasil**. Capítulo 7: habitação por conta do trabalhador.

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

BLASCHKE, T.; LANG, S.; HAY, G. J. (Eds.). **Object-based image analysis**. Berlin: Springer-Heidelberg, 2008. p. 75–89.

CASTILHO, Juliana Vargas de. **A favelização do espaço urbano em São Paulo. Estudo de caso: Heliópolis e Paraisópolis**. Tese de Doutorado. Universidade de São Paulo. 2013.

HAY, G. J.; CASTILLA, G. **Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline**. In: BLASCHKE, T.; LANG, S.; HAY, G. J. (Eds.). **Object-based image analysis**. Berlin: Springer-Heidelberg, 2008. p. 75–89.

HOFMANN, P.; STROBL, J.; BLASCHKE, T.; KUX, H. **Detecting informal settlements from QuickBird data in Rio de Janeiro using an object-based approach**. Berlin: Springer-Heidelberg, 2008. p. 531–553.

IBGE, **Aglomerados subnormais 2019: classificação preliminar e informações de saúde para o enfrentamento à COVID-19: notas técnicas**. IBGE, Rio de Janeiro. 2020.

INPE. **Câmeras Imageadoras CBERS-4A**. INPE. 2019. Disponível online: <http://www.cbers.inpe.br/sobre/cameras/cbers04a.php>

INPE. **Sobre o CBERS**. INPE. 2018. Disponível online: <http://www.cbers.inpe.br/sobre/index.php>

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. Upper Saddle River: Prentice Hall, 1998.

KOHLI, Divyani; KERLE, Norman; SLIUZAS, Richard. **Local ontologies for object-based slum identification and classification. Proceedings of the 4th GEOBIA**, Rio de Janeiro, ano 2012, p. 201-205, 7 mai. 2012. Semanal.

KOHLI, D.; SLIUZAS, R.V.; STEIN, A. / **Urban slum detection using texture and spatial metrics derived from satellite imagery**. In: Journal of spatial science. 2016; Vol. 61, No. 2. pp. 405-426.

KUX, H.; NOVACK, T.; FONSECA, L. **Mapeamento de favelas usando classificação orientada a objeto – estudo de caso em Paraisópolis, São Paulo (SP)**. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 715-721.

LANDIS, R. J.; KOCH, G. G. **The Measurement of Observed Agreement for Categorical Data**. Biometrics, v. 33, n. 1, p. 159–174, 1977.

MACHADO, Cláudia Aparecida Soares. **Determinação do índice de acessibilidade do município de Osasco/SP pelo uso de imagens de alta resolução espacial e SIG - uma proposta metodológica**. 2007. Dissertação (Mestrado em Engenharia de Transportes) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2007.

MACHADO, Cláudia Aparecida Soares. **Técnicas de sensoriamento remoto para identificação de áreas de concentração de polos geradores de viagens**. 2013. Tese (Doutorado em Engenharia de Transportes) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2013.

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

NOVACK, T.; KUX, H. **Urban land cover and land use classification of an informal settlement area using the open-source knowledge-based system InterIMAGE**, Journal of Spatial Science, 55:1, 2010, 23-41.

PASTERNAK, S., D'OTTAVIANO, C. **Favelas no Brasil e em São Paulo: avanços nas análises a partir da Leitura Territorial do censo de 2010**. Cadernos da Metrópole, 2016, v. 18, n. 35, p. 75-99. Doi.org/10.1590/2236-9996.2016-3504.

PEDRASSOLI, J. C. **Análise Orientada a Objeto para detecção de favelas e classificação do uso do solo em Taboão da Serra/SP**. Orientador: Prof. Dr. Ailton Luchiari. 2011. Dissertação (Mestrado) - Curso de GEOGRAFIA, DEPARTAMENTO DE GEOGRAFIA, UNIVERSIDADE DE SÃO PAULO, São Paulo, 2011.

PEDRO, Alexandra Aguiar; QUEIROZ, Alfredo Pereira. **Slum: Comparing municipal and census basemaps**. Habitat International, Holanda: Elsevier, ed. Volume 83, ano 2019, p. 30- 40, 15 jan. 2019.

RAMOS, Diego Vieira et al. **Técnicas de sensoriamento remoto empregadas nos estudos urbanos de transporte**. Synergismus Scyentifica UTFPR, Pato Branco, v. 12, n. 1, p. 269 – 278, 2017.

ROSA, Marcos Reis. **Classificação do Padrão de Ocupação Urbana de São Paulo Utilizando Aprendizagem de Máquina e Sentinel 2**. Revista do Departamento de Geografia, São Paulo, n. ISSN 2236-2878, p. 15-21, 26 ago. 2018.

SANTOS, B.D.; de Pinho, C.M.D.; Oliveira, G.E.T.; Korting, T.S.; Escada, M.I.S.; Amaral, S. **Identifying Precarious Settlements and Urban Fabric Typologies Based on GEOBIA and Data Mining in Brazilian Amazon Cities**. Remote Sens. 2022, 14, 704.

SANTOS, Milton. **Técnica Espaço Tempo - globalização e meio técnico-científico e informacional**. São Paulo, Hucitec, 2004. Cap. 13 Meio técnico-científico-informacional e urbanização do Brasil.

SEADE. **População total do Município de São Paulo**. Fundação Sistema Estadual de Análise de Dados (SEADE). 2022. Disponível online: <https://populacao.seade.gov.br/populacao-2022-msp/>