DANIELE LIMA BARROS

**Identificação de padrões de uso do solo urbano em São Paulo/SP utilizando
parâmetros de variogramas**

**São Paulo
2015**

DANIELE LIMA BARROS

**Identificação de padrões de uso do solo urbano em São Paulo/SP utilizando
parâmetros de variogramas**

Dissertação apresentada à Escola
Politécnica da Universidade de São Paulo
para obtenção do título de Mestre em
Ciências

**São Paulo
2015**

DANIELE LIMA BARROS

**Identificação de padrões de uso do solo urbano em São Paulo/SP utilizando
parâmetros de variogramas**

Dissertação apresentada à Escola
Politécnica da Universidade de São Paulo
para obtenção do título de Mestre em
Ciências

Área de Concentração:
Engenharia de Transportes

Orientador:
Dra. Ana Paula Camargo Larocca

**São Paulo
2015**

Este exemplar foi revisado e alterado em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, 17 de junho de 2015

Assinatura do autor

Assinatura do orientador

Catálogo-na-publicação

Barros, Daniele Lima
Identificação de padrões de uso do solo urbano em São Paulo/SP
utilizando parâmetros de variogramas / D. L. Barros – São Paulo, 2015
86p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São
Paulo. Departamento de Engenharia de Transportes.

1.Sensoriamento remoto 2.Geoestatística 3.Ambientes urbanos

Universidade de São Paulo. Escola Politécnica.
Departamento de Engenharia de Transportes

AGRADECIMENTOS

Agradeço à Profa. Dra. Ana Paula Larocca e ao PTR – Poli –USP pela oportunidade da realização desta pesquisa.

Ao Prof. Dr. José Alberto Quintanilha e à Profa. Dra. Mariana Giannotti pela orientação.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPQ pelo apoio financeiro.

A Patrícia Santana pela paciência e pelas inúmeras orientações e ajuda quanto aos procedimentos burocráticos, bem como, datas e prazos da pós-graduação.

Ao Prof. Dr. Marcelo Rocha e Sidney Gouveia pelas orientações em Geoestatística.

Meu muito obrigada às “meninas do laboratório” Juliana Kolling, Janaina Silva e Luciana Spigolon pela amizade, apoio e ajuda de todas as formas.

Às amigas de todos os momentos Natália Costa, Natália Gallo Albuquerque, Maria Cristina Machado de Lima, Thaís Parolin, Érica Rocha de Góes e Aline Biaseto Bernhard.

Aos amigos que fiz durante o período de realização das disciplinas, Renata Sayuri Kawashima, Rodrigo de Sousa Pissardini, Pedro Luiz Facin e Lucas Spinola Costa.

Meu muito obrigada ao Diego Biaseto Bernhard companheiro de longa data que me apoiou e ajudou sempre que pôde e que muitas vezes acreditou mais em mim do que eu mesma

À minha mãe, Valderês Gomes Lima e à minha irmã Denise Lima Barros.

RESUMO

As imagens de alta resolução espacial impulsionaram os estudos de Sensoriamento Remoto em ambientes urbanos, já que elas permitem uma melhor distinção dos elementos que compõem esse ambiente tão heterogêneo.

Técnicas de Geoestatística são cada vez mais utilizadas em estudos de Sensoriamento Remoto e o variograma é uma importante ferramenta de análise geoestatística, pois permitem entender o comportamento espacial de uma variável regionalizada, neste caso, os níveis de cinza de uma imagem de satélite.

O presente trabalho pretende avaliar a proposta metodológica que consiste em identificar padrões residenciais urbanos de três classes de uso e ocupação do solo por meio da análise dos valores apresentados pelos parâmetros, alcance, patamar e efeito pepita de um variograma. A hipótese é que os valores correspondentes a esses parâmetros representem o comportamento espectral padrão de cada classe e, portando, indicam que há um padrão na organização espacial de cada uma das classes.

Para a presente pesquisa foram utilizadas imagem IKONOS 2002, e a classificação de uso e ocupação do solo da sub-bacia do córrego Bananal na bacia do Rio Cabuçu de Baixo em São Paulo – SP. Amostras das imagens de cada classe foram extraídas e os valores de nível de cinza em cada pixel foram utilizados para calcular os variogramas.

Após análise dos resultados obtidos, apenas o parâmetro alcance foi levado em consideração, pois é através desse parâmetro que se observa o grau de homogeneidade de cada amostra. Os valores de alcance obtidos nos cálculos dos variogramas identificaram com melhor precisão a classe “Conjuntos Residenciais” que é uma classe com padrões e características singulares, já a identificação das classes “Ocupação Densa Regular” e “Ocupação Densa Irregular” não obteve uma precisão boa, sendo que essas classes são similares em diversos aspectos.

Palavras chave: Sensoriamento Remoto, geoestatística, variograma, padrões urbanos.

ABSTRACT

The images of high spatial resolution studies of leveraged Remote Sensing in urban environments, as they enable better distinction of the elements that make up this very heterogeneous environment.

Geostatistical techniques are increasingly used in studies of Remote Sensing, the variogram is an important tool geostatistical analysis, because it allows to understand the spatial behavior of a regionalized variable, in this case, the gray levels of a satellite image.

This study aims to assess the methodological proposal is to identify urban residential patterns of three classes of use and occupation of land by the analysis of the figures presented by the parameters, scope, and level of a nugget effect variogram. The hypothesis is that the values corresponding to these parameters represent the standard of each class spectral behavior and bearing indicate that there is a pattern in the spatial organization of each class.

IKONOS 2002 image were used for this research, and the classification of the use and occupation of the stream Banana plantation sub-basin in the Rio Cabuçu Low Bowl in Sao Paulo - SP. Samples of stock were taken from each class and the values of gray level in each pixel are used to calculate the variogram.

After analyzing the results, only the parameter range was taken into account , because it is through this parameter is observed the degree of homogeneity of each sample.

The range of values obtained in the calculation of variograms identified with better accuracy class "Multiple Dwelling Unit" which is a class with unique patterns and characteristics, since the identification of classes "Regulated Dense Occupation" and "Irregular Dense Occupation" did not get a good precision since the classes are similar in several respects.

Keywords: Remote Sensing, geostatistics, variogram, urban patterns.

LISTA DE FIGURAS

Figura 1: Comportamento espectral de materiais comumente encontrados em ambientes urbanos. Fonte: Sousa e Kux (2005).....	13
Figura 2: Exemplos de configurações espaciais urbanas. Fonte: Brito e Quintanilha (2013)	16
Figura 3: Variograma típico e suas propriedades. Fonte: Yamamoto (2002)	21
Figura 4: Amostras distribuídas regularmente. Fonte: Camargo e Fucks (2001).....	22
Figura 5: Amostras distribuídas irregularmente. Fonte: Camargo e Fucks (2001)	22
Figura 6: Exemplo de um dos conjuntos de amostras, com distribuição regular utilizados nesta pesquisa. Fonte: Barros, 2015.....	23
Figura 7: Desenho esquemático de cálculo do variograma a partir de amostras regularmente distribuídas. Fonte: Camargo e Fucks (2001)	24
Figura 8: Modelos teóricos de ajuste de variograma. Fonte: modificado de ESRI.	24
Figura 9: Desenho esquemático do fenômeno espacial isotrópico. Fonte: Yamamoto e Landim (2013)	25
Figura 10: Desenho esquemático do fenômeno espacial anisotrópico. Fonte: Yamamoto e Landim (2013)	26
Figura 12: Localização da área de estudo. Fonte: Barros (2004)	32
Figura 13: Mapa de uso da Bacia do Rio Cabuçu de Baixo. Fonte: Barros (2004).....	33
Figura 15: Exemplo de uma das configurações encontradas na área analisada. Fonte: Barros (2004)	35
Figura 16: Imagem IKONOS. Fonte: Nóbrega (2007)	38
Figura 17: Mapa de uso e ocupação do solo com destaque para a sub-bacia do córrego Bananal. Fonte: LGP/PTR/Poli/USP	40
Figura 18: Polígonos das classes analisadas sobrepostos à imagem IKONOS. Fonte: Barros (2014)....	41
Figura 19: Fluxo simplificado do método utilizado. Fonte: Barros (2014)	42
Figura 20: Estatísticas da análise por Componentes Principais. Fonte: Barros (2014)	43
Figura 21: Exemplo das amostras de CP1 de cada classe analisada.	45
Figura 22: Exemplo da malha de pontos com os valores digitais de cada pixel. Fonte: Barros (2014)	47
Figura 23: Exemplo de como direção preferencial da variância coincide com a orientação dos elementos da imagem. Fonte: Barros (2014).....	51

Figura 24: Repetição de padrões da classe “Conjuntos Residenciais”	54
Figura 25: Comparação de algumas amostras das classes “Ocupação Densa Regular” e “Ocupação Densa Irregular”. Fonte: Barros (2014)	55

LISTA DE QUADROS

Quadro 1 : Descrição das classes analisadas.....	37
Quadro2: Principais características do satélite IKONOS II.	39
Quadro 3: Estatística básica da classe “Conjuntos Residenciais”	45
Quadro 4: Estatística Básica da classe “Ocupação Densa Irregular”	46
Quadro 5: Estatística Básica da classe “Ocupação Densa Regular”	46
Quadro 6: Sistematização dos resultados da classe “Conjuntos Residenciais”	48
Quadro 7: Sistematização dos resultados da classe “Ocupação Densa Regularizada”	49
Quadro 8: Sistematização dos resultados da classe “Ocupação Densa Irregular”	50
Quadro 9: Valores dos parâmetros “Conjuntos Residenciais”	51
Quadro 10: Valores dos parâmetros “Ocupação Densa Regularizada”	52
Quadro 11: Valores dos parâmetros “Ocupação Densa Irregular”	52
Quadro 12: Estatística descritiva básica dos valores de alcance das classes”	53

SUMÁRIO

1.	INTRODUÇÃO	1
1.1.	HIPÓTESE	3
1.2.	OBJETIVOS	3
1.2.1.	Objetivo geral	3
1.2.2.	Objetivo específico	3
2.	REVISÃO BIBLIOGRÁFICA.....	5
2.1.	SENSORIAMENTO REMOTO UTILIZADO EM ANÁLISES URBANAS.....	6
2.2.	CLASSIFICAÇÃO DE USO E OCUPAÇÃO DO SOLO URBANO	9
2.3.	COMPORTAMENTO ESPECTRAL DE ALVOS URBANOS	12
3.	MORFOLOGIA URBANA E INTRAURBANA	15
4.	GEOESTATÍSTICA	19
4.1.	VARIOGRAMA.....	19
4.1.1	Conceitos iniciais	19
4.1.2	Parâmetros de um variograma	20
4.1.3	Mapas variográficos	26
4.2.	GEOESTATÍSTICA E SENSORIAMENTO REMOTO APLICADOS AOS ESTUDOS EM AMBIENTES URBANOS	27
4.3.	O CONCEITO DE TEXTURA EM IMAGENS DE SENSORIAMENTO REMOTO.....	29
5.	ÁREA DE ESTUDO	32
5.1.	DESCRIÇÃO DAS CLASSES ANALISADAS.....	35
6.	MATERIAIS E MÉTODO	38
6.1.	MATERIAIS.....	38
6.1.1.	Imagem de satélite e mapa	38
6.1.2.	Programas	41
6.2.	MÉTODO PROPOSTO	42
7.	RESULTADOS E DISCUSSÕES.....	48
8.	CONCLUSÕES.....	56
9.	REFERÊNCIAS BIBLIOGRÁFICAS	59
	ANEXO I	

1. INTRODUÇÃO

O desenvolvimento de grandes cidades tem sido rápido e frequentemente a expansão urbana não é planejada e, muitas vezes, até desconhecida. Estudar a dinâmica de desenvolvimento e crescimento das cidades é um grande desafio para várias áreas do saber, pois o ambiente urbano é dotado de uma série de características peculiares e processos que se conectam formando uma intrincada malha urbana.

As consequências do crescimento desordenado das grandes cidades geram os conhecidos problemas como congestionamentos, transporte público deficiente e a falta de saneamento básico; além das disparidades socioeconômicas, como crimes e a alta vulnerabilidade a desastres naturais como enchentes, devido à alta impermeabilização do solo e deslizamentos de terra, em razão da ocupação desordenada de encostas (Taubenböck et al.,2012).

De acordo com dados do censo demográfico realizado pelo IBGE em 2010 a população brasileira é de 190.732.694 habitantes, 84% desses vivendo em áreas urbanas. Esses dados indicam a grande importância dos estudos urbanos pelas diversas áreas do conhecimento e as imagens de Sensoriamento Remoto de alta resolução são uma poderosa ferramenta para este fim.

A sub-bacia do Córrego Bananal, escolhida como área de estudo para esta pesquisa, reflete bem a dinâmica supracitada, ela é uma das bacias que compõem a Bacia do Rio Cabuçu de Baixo e está localizada no extremo norte da cidade de São Paulo. A área do Córrego Bananal é caracterizada pela presença de ocupações irregulares fruto de invasões e auto construções, apresenta alta densidade populacional e alta taxa de impermeabilização.

Foram analisadas três classes de uso e ocupação do solo de cunho residencial “Conjuntos Residenciais”, formada por conjuntos habitacionais fruto de programas governamentais de acesso à moradia; “Ocupação Densa Regularizada”, formada por moradias de classe média/baixa, mas que estão em uma área regularizada pelo município; “Ocupação Densa Irregular”, formadas por moradias de classe baixa em ruas e lotes não regularizados pelo município.

Os problemas residenciais brasileiros mais comuns são: a segregação espacial da população pobre em assentamentos informais, escassez de moradia e infraestrutura urbana, precariedade do transporte público, dificultando o acesso da população aos postos formais de trabalho e emprego, além da ocupação de áreas de risco ou protegidas por leis ambientais (Leão, 2011).

Monitorar esse cenário de constantes transformações é um grande desafio para gestores e planejadores urbanos. A evolução das geotecnologias e das técnicas de processamento de imagens elevaram a outro patamar os estudos urbanos. Os Sistema de Informações Geográficas (SIG's) permitem integrar e gerenciar informações o que permitiu potencializar as análises espaciais e, com maior nível de precisão é possível um melhor entendimento da dinâmica urbana. (Salim, 2013)

Desta maneira, os dados históricos de sensoriamento remoto têm sido utilizados frequentemente para medir, analisar e entender a expansão urbana, gerando assim informações sobre a variação do uso e cobertura da terra, de análises da morfologia entre outras muitas aplicações (Patino e Duque, 2013).

Até meados de 1999, com o lançamento dos sistemas IKONOS II e QUICKBIRD II que proporcionaram um grande salto nos estudos urbanos devido à alta resolução espacial de suas imagens, os estudos de Sensoriamento Remoto ocupavam-se com análises de cobertura do solo e da dinâmica espaço-tempo com estudos baseados em séries temporais de imagens.

Os avanços tecnológicos das imagens de Sensoriamento Remoto, com a evolução das resoluções espacial e espectral, aumentaram a eficiência na obtenção de dados de cobertura do solo em ambientes urbanos por fornecer imagens com maior detalhamento.

Juntamente com a evolução dos sistemas sensores, os métodos de análise de imagens orbitais também evoluíram e se diversificaram. Desde a década de 1980 métodos geoestatísticos têm sido aplicados em imagens de Sensoriamento Remoto para quantificar a estrutura e a textura de imagens, definir escalas ideais, realizar estimativas baseadas em krigagem, realçar informações de imagens, completar informações ausentes em pixels, diminuir a resolução de imagens, entre outros (Van Der Meer, 2012).

A geoestatística refere-se ao conjunto de técnicas para análise de dados que é tipicamente aplicada a variáveis regionalizadas, as quais são variáveis com posição espacial conhecida. Espera-se que essas variáveis sejam espacialmente dependentes, significando que pontos próximos um do outro são mais parecidos que aqueles distantes entre si (Isaaks e Srivastava, 1989).

1.1. HIPÓTESE

Este trabalho parte do princípio de que o nível de cinza de um pixel de uma imagem de sensoriamento remoto orbital, que é proporcional à quantidade de energia eletromagnética refletida e ou emitida pelos alvos terrestres, pode ser considerado uma variável regionalizada, podendo, portanto ser modelado por uma função variograma.

1.2. OBJETIVOS

1.2.1. Objetivo geral

Avaliar se a variografia é capaz de assimilar o comportamento espectral das classes analisadas e identificar padrões de uso e ocupação do solo em ambiente urbano.

1.2.2. Objetivo específico

Averiguar de que maneira o uso do variograma, a partir de amostras de diferentes tipos de cobertura urbana obtidas de imagens de satélites de alta resolução espacial, pode ser uma ferramenta importante para auxiliar a classificação da cobertura do solo urbano.

Além deste capítulo introdutório, composto também por hipótese e objetivos, a presente pesquisa está organizada em mais oito capítulos. O Capítulo 2 apresenta a Revisão Bibliográfica com noções gerais de Sensoriamento Remoto em análises urbanas, classificação de uso e ocupação do solo urbano e comportamento

espectral de alvos urbanos. O Capítulo 3 trata da Morfologia Urbana e intra-urbana; O Capítulo 4 apresenta conceitos básicos de Geoestatística e uma revisão bibliográfica sobre Geoestatística e Sensoriamento Remoto, Geoestatística e Sensoriamento Remoto aplicados aos estudos em ambientes urbanos e o conceito de textura em imagens de Sensoriamento Remoto. O Capítulo 5 apresenta a área de estudo. O Capítulo 6 trás os materiais e o método utilizados neste estudo. O capítulo 7 é composto pelos resultados e discussões. O Capítulo 8 trás as conclusões e o Capítulo 9 as referências bibliográficas.

2. REVISÃO BIBLIOGRÁFICA

O ambiente urbano é objeto de estudos de diversas áreas do conhecimento motivados por sua complexidade, que vem da heterogeneidade de elementos, materiais, formas e relações que compõem a malha urbana.

O escopo deste trabalho, conforme relatado anteriormente, consiste em avaliar a proposta metodológica de identificação de padrões de cobertura urbanos em uma imagem de Sensoriamento Remoto de alta resolução espacial através do cálculo de variogramas e parâmetros associados, que é uma importante ferramenta geoestatística, sobre as respostas espectrais de três classes de ocupação residencial, que serão descritas em capítulos posteriores.

Desta maneira, o levantamento bibliográfico foi realizado considerando as áreas do conhecimento pertinentes ao pano de fundo deste trabalho, como, noções gerais de Sensoriamento Remoto nos estudos urbanos e noções gerais de Geoestatística aplicada, neste caso, às análises de imagens de Sensoriamento Remoto.

Abordagem similar a este trabalho é adotada por Woodcock et al. (1988), Brito e Quintanilha (2013) e Balaguer-Beser et al. (2013). Em Woodcock et al. (1988) o objetivo dos autores foi “estabelecer uma relação direta entre as características espaciais das imagens e da cena de onde a imagem foi derivada.” Esta pesquisa difere das outras no momento em que se assume que os números digitais expressos em pixels não são informações pontuais, desta maneira todos os variogramas são regularizados e utilizou uma banda monocromática. Neste caso assumiu-se que imagens urbanas são intrinsecamente heterogêneas e que os pixels são informações pontuais.

Brito e Quintanilha (2013) utilizaram padrões urbanos pré-definidos como o que foi feito na presente pesquisa, mas com foco em análise baseada em objeto (OBIA) para classificar coberturas e não aplicaram a variografia. Em Balaguer-Beser et al. (2013), um conjunto de imagens de referência foi usado para avaliar abordagens computacionais no cálculo de variogramas experimentais e seus parâmetros para caracterizar padrões espaciais. Esses autores usaram um tipo diferente de parâmetros para caracterização da forma do variograma próximo à origem: a relação entre os valores da variância total e a semivariância no primeiro *lag* (RVF); a relação

entre os valores da semivariância no segundo e primeiro *lag* (RSF); primeira derivação próxima à origem (FDO) e a segunda derivação no terceiro *lag* (SDT), que consideraram como relevante para definir as mudanças em uma imagem e a variação contínua.

A contribuição da presente pesquisa na caracterização de padrões espaciais urbanos usando imagens multiespectrais reduzidas por componentes principais e discriminação desses padrões pelo valor de alcance dos variogramas de diferentes tipos de ocupação do solo.

Durante o levantamento bibliográfico, os trabalhos referentes à determinação ou detecção ou ainda identificação de padrões urbanos perpassam por considerações sobre a morfologia urbana, textura e espaço intra-urbano que também serão abordados nesta revisão bibliográfica.

2.1. SENSORIAMENTO REMOTO UTILIZADO EM ANÁLISES URBANAS

O Sensoriamento Remoto é um recurso eficiente na obtenção de dados sobre o uso e cobertura do solo, os recentes avanços tecnológicos aprimoraram as resoluções espaciais e espectrais dos sistemas sensores e permitiram análises em ambiente urbano de maneira mais detalhada.

Entre as diversas definições de Sensoriamento Remoto encontradas na bibliografia consultada, a que será considerada neste trabalho por ser a mais completa e abrangente é a de Novo (2011) “a utilização conjunta de sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados, colocados a bordo de aeronaves, espaçonaves ou outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta Terra a partir do registro e da análise das interações entre a radiação eletromagnética e as substâncias que o compõem em suas mais diversas manifestações”.

A “segunda geração” de satélites forneceu imagens de resoluções entre 10 e 30 m e a “terceira geração” de sensores de altíssima resolução espacial, menores que 5 m estimularam o desenvolvimento do sensoriamento remoto em análises urbanas já que esse tipo de dado facilita uma maior distinção dos objetos (Doney *et. al.*, 2001).

As aplicações de Sensoriamento Remoto mais comuns em áreas urbanas são: a caracterização, a identificação, a classificação e as quantificações dos materiais, da composição e da estrutura próprios das construções urbanas (Weng, 2008), das aplicações ambientais e econômicas como, ilhas de calor, qualidade ambiental urbana, estimativa demográfica, variáveis socioeconômicas, entre outras.

O tecido urbano é muito heterogêneo, pois é composto por materiais, formas e texturas das mais variadas, além de ser palco para os mais diversos tipos de uso e ocupação. Desta maneira, as imagens de satélite de alta resolução aumentaram exponencialmente a capacidade de análise desse ambiente, já que permitem detectar sua variabilidade morfológica com maior precisão.

Diferente do que acontece em ambientes não urbanos, onde é relativamente fácil associar o comportamento espectral de dois dos maiores componentes dos ecossistemas terrestres (água e vegetação) e uso do solo, no meio urbano um grande problema é conseguir individualizar classes, já que neste tipo de ambiente, comportamentos espectrais semelhantes podem significar diferentes tipos de uso do solo e variadas funções (Doney *et. al.*, 2001). O trabalho de Pinho e Almeida (2005) salienta a dificuldade em separar “ruas pavimentadas com asfalto e edificações com cobertura de amianto escuro”.

Nesse trabalho os autores analisaram a influência do tipo de padrão de ocupação urbana levando em consideração o grau de homogeneidade do tamanho, forma, tipos de cobertura e distribuição espacial no resultado da análise orientada a objetos em áreas intra-urbanas. Quanto mais complexo o padrão de ocupação do solo, ou seja, maior variedade de materiais de cobertura e tamanho das edificações e, portanto, uma baixa definição de arranjo espacial, pior é o resultado da classificação, demonstrando que essas diferenças de padrão devem ser consideradas na análise de imagens orbitais de alta resolução espacial.

O trabalho de Quintanilha e Silva (2005) discute problemas similares aos supra mencionados. No caso, utilizando imagens IKONOS. A expectativa inicial dos autores era de que fosse possível separar ruas com diferentes tipos de asfaltos, o que não foi possível uma vez que ruas de tráfego intenso têm seu recapeamento frequentemente renovado, tornando o asfalto escuro e pouco rugoso assim como os

serviços de limpeza pública, nesse tipo de rua, resulta em ruas com pouca sujeira. A distinção entre outras classes também é limitada:

- 1) nuvens de áreas com alta densidade de vegetação verde (sadia) se confundem com as ruas de asfalto escuro;
- 2) o asfalto claro se confunde com o concreto, uma vez que ambos têm a mesma origem (hidrocarbonatos).

A causa principal proposta pelos autores para essas confusões é a baixa resolução espectral do IKONOS, corroborando o trabalho de Herold et al. (2002), que comparou dados de campo obtidos por espectrômetro e os comparou com dados de cobertura obtidos do IKONOS, LANDSAT TM e do sensor hiperespectral do AVIRIS. Esses autores mostraram que as diferenças para alvos urbanos, são pequenas para os sensores multi e hiperespectrais e, no caso do IKONOS, apresentam alguns picos baixos significantes que limitam a separabilidade de alguns alvos.

A fim de monitorar e modelar a dinâmica da expansão urbana no tempo, Jat et al. (2008) e Sudhira et al. (2004) utilizaram técnicas de Sensoriamento Remoto e de Sistemas de Informação Geográfica, Taubenböck et al. (2012) também fazem uso desses recursos para monitorar a urbanização de megacidades.

Ridd (1995) explora o modelo V-I-S, algo como, vegetação, superfície impermeável e solo, para ecossistemas urbanos. Esse modelo serve como base para a caracterização de ambientes urbanos e para comparação de morfologias dentro e entre cidades, além de ser útil para a detecção de alterações no ambiente urbano, modelagem de expansão urbana, análise de impacto ambiental da urbanização, entre outros.

Quintanilha et al. (2006), Nóbrega et al. (2006 e 2008), Souza et al. (2007 e 2009), Pinho et al. (2012) são exemplos do uso de classificação orientada a objetos em imagens de alta resolução espacial de cidades brasileiras. Duriex et al. (2008), Pacifici et al. (2009), Blaschke (2010), Tewold e Cabral (2011) e Giannini et al. (2012) também utilizaram OBIA para estudos de expansão urbana, ou para mapeamento do uso do solo urbano.

Revisões recentes e mais abrangentes sobre o uso de Sensoriamento Remoto orbital para estudos urbanos estão em Brito e Quintanilha (2012), Machado et al. (2014), assim como Patino e Duque (2013).

Nesta seção serão elencados os temas mais recorrentes em trabalhos de Sensoriamento Remoto em estudos no meio urbano de acordo com a literatura consultada.

2.2. CLASSIFICAÇÃO DE USO E OCUPAÇÃO DO SOLO URBANO

Desde os primórdios dos estudos de imagens de satélite, a resolução espectral dessas imagens são a principal fonte de dado para a discriminação de alvos, as técnicas e algoritmos desenvolvidos para classificar o uso e ocupação do solo são os mais diversos. No caso de estudos urbanos, a classificação orientada a objetos é bastante utilizada por possibilitar a análise do comportamento espectral dos alvos, bem como a consideração de outros atributos como forma, textura, contexto, entre outros (Salim, 2013).

Alves e Vergara (2005) propuseram uma metodologia de dados orientados a segmentos para classificação de áreas urbanas em imagens de satélite de alta resolução espacial e avaliaram a capacidade das imagens IKONOS de fornecerem informações temáticas necessárias para o apoio à atualização de cadastros urbanos, utilizando classificação orientada a segmentos.

Em sua tese de doutorado, Nóbrega (2007) trabalha a detecção da malha viária na periferia de São Paulo através da classificação orientada a objetos (Quintanilha et al., 2006); Pinho et al. (2005) compararam os métodos de classificações de cobertura do solo urbano pixel-a-pixel e orientada a objetos em uma imagem IKONOS, concluíram que o método orientado a objetos mostrou-se superior ao identificar com mais precisão um maior número de classes. Nóbrega et al. (2006 e 2008) apresentam resultados que a metodologia OBIA produz informações significantes e oferece incrementos em relação aos métodos tradicionais pixel a pixel na extração e classificação de vias urbanas.

No intuito de caracterizar a situação socioeconômica de uma área residencial Souza et al. (2007) e Souza et al. (2009) utilizam a classificação orientada a objetos em uma imagem de alta resolução espacial. Os autores definiram as classes alta, média

e baixa a partir de características próprias de cada classe, por exemplo, a classe alta se caracteriza pela presença de piscinas, vegetação e telhado cerâmico em maior quantidade do que nas demais classes. A metodologia mostrou-se eficaz evidenciando que é possível caracterizar a situação socioeconômica de uma população a partir da análise de suas características espaciais e construtivas.

Antunes e Duarte (2012) caracterizaram o crescimento de áreas urbanas a partir de uma imagem QUICKBIRD utilizando classificação baseada em segmentos. Os autores atingiram resultados satisfatórios após incluírem na análise atributos de conceito, textura e vizinhança.

Huang et al. (2008) Comparam duas abordagens para classificação de cobertura do solo, uma que utiliza uma janela fixa e outra em que varia o tamanho da janela de acordo com os resultados da análise dos variogramas para extração de textura em uma imagem SPOT5. A avaliação da acurácia geral, considerando todas as classes analisadas, mostrou que enquanto o método de janela fixa apresentou 80,96% de acurácia, o método de janela flexível apresentou 86,02%, portanto, houve uma melhora significativa da acurácia geral de uso e cobertura do solo.

De acordo com Kochhan e Gleyzes (2012) e Taubenböck et al. (2012), devido à sua complexidade geográfica, as megacidades são muito peculiares quanto aos aspectos culturais, ambientais, socioeconômicos e demográficos, bem como quanto aos serviços básicos de infraestrutura, tais como energia, abastecimento de água, telefonia, sistemas de transportes, etc. Os problemas gerados nas megacidades possuem a mesma magnitude “mega”, e são mais evidentes nos mercados emergentes, onde a maioria das megacidades está localizada.

A massiva e rápida dinâmica de expansão das megacidades sobrecarrega a capacidade de governar, administrar, organizar e planejar os novos assentamentos oriundos do crescimento urbano, e muitas vezes até mesmo a documentação e mensuração do que realmente ocorreu é uma tarefa difícil. No entanto, na maioria dos casos há uma grande quantidade de informações e dados espaciais (quantitativos e qualitativos), mas estes conjuntos de dados raramente são facilmente acessíveis sem restrições quanto ao seu uso. Além disso, quase nunca são apresentados de forma completa, consistente, padronizada, atualizada e com informações de metadados. Isto tudo dificulta muito os estudos comparativos com

outras megacidades, pois a análise, mensuração e entendimento do complexo processo de urbanização precisam avançar além dos estudos de casos isolados (Taubenböck, et al., 2012). Assim, é necessária uma organização independente e consistente da fonte de dados a fim de evitar os problemas mencionados e proporcionar estudos comparativos centrados nas tendências e padrões globais de urbanização. Além disso, quando se trata do estudo de megacidades, é necessário disponibilizar dados de monitoramento de longos períodos de tempo e de extensas áreas de cobertura. Para preencher esses requisitos a ciência do sensoriamento remoto se apresenta capaz de prover tais dados de caráter espaço-temporal a partir das imagens dos satélites de observação da Terra (Taubenböck et al., 2012).

De acordo com Machado et al. (2014), estudos nesse sentido têm sido conduzidos por diversos pesquisadores, dentre eles destaca-se Esch et al. (2012) que monitoraram a urbanização global por meio de séries temporais baseadas em dados de observação da superfície terrestre, aplicaram técnicas de classificação de imagem baseadas em objetos e também em pixel em imagens de alta e média resolução espacial de sensores ópticos e de RADAR, que cobriu um período de 40 anos (em intervalos de 10 anos) para monitorar o crescimento urbano de 27 megacidades em todo o mundo; Wang et al. (2012) determinaram a expansão urbana das médias, grandes e megacidades da China durante o período de 1990 a 2010 a partir do Sensoriamento Remoto orbital, desenvolveram métodos automáticos de mapeamento do uso do solo através da aplicação de técnicas de processamento digital e classificação de imagens de satélites; e Kit et al. (2012) utilizaram dados de Sensoriamento Remoto para identificar, a partir de elementos de textura nas imagens, favelas urbanas na área de uma megacidade na Índia; Kuffer e Barros (2011) empregaram imagens de sensoriamento remoto na extração de dados e informações necessários para a elaboração de métricas espaciais a serem aplicadas na identificação morfológica de aglomerações urbanas com ausência de planejamento na megacidade de Nova Deli, na Índia; e finalmente, Schwarz (2010) usou os produtos de sensoriamento remoto para extração de informações e dados de indicadores de forma urbana para a formulação de métricas aplicadas no planejamento urbano de 231 cidades em 27 países na Europa.

2.3. COMPORTAMENTO ESPECTRAL DE ALVOS URBANOS

O comportamento espectral de alvos urbanos é uma informação importante na classificação do uso do solo através de imagens de satélite, principalmente em imagens de baixa resolução espacial, pois o comportamento espectral pode indicar as características e dinâmicas de uma área (Souza e Kux, 2005 e Pinho et al. 2009).

O comportamento espectral ou assinatura espectral é a variação da refletância em função do comprimento da onda eletromagnética, ou seja, é o comportamento de cada material em relação à quantidade de energia eletromagnética refletida. Conhecer como os diferentes elementos terrestres respondem os sensores em relação à energia eletromagnética é imprescindível para os estudos em sensoriamento remoto (Alvarenga, 2012).

O estudo do comportamento espectral dos alvos urbanos segue duas linhas de pesquisa, uma que considera como alvos urbanos os materiais que compõem esse ambiente como asfalto, concreto, materiais dos telhados, entre outros; já a outra linha considera como alvos urbanos os tipos de ocupação como, residencial, industrial (Vieira et al., 1989).

Vieira et al. (1989) apresentam um procedimento metodológico para discriminação de áreas residenciais em bairros de São José dos Campos – SP. Esse trabalho teve como objetivo avaliar a relação entre componentes radiométricos dos elementos presentes no alvo e nos níveis digitais obtidas na imagem. A metodologia utilizada envolveu a estimativa de refletância para alvos urbanos a partir da integração das medidas radiométricas dos elementos.

Essa pesquisa atingiu resultados relativamente bons, apesar da baixa representatividade quantitativa e qualitativa, ela permitiu que os autores alcançassem conclusões importantes para o aprofundamento da pesquisa nesse tema. Os autores concluíram que as características de ocupação se manifestam na resposta espectral; é possível estabelecer parâmetros viáveis para o estudo do comportamento espectral de alvos urbanos em tipos específicos de ocupação do solo.

O tecido urbano apresenta grande heterogeneidade de materiais, Pinho e Novack (2009) analisaram métodos de extração de diferentes tipos de telhados em imagens

multiespectrais de alta resolução espacial a partir de espectros obtidos em laboratório. Como método de trabalho foram escolhidas oito amostras de telhados de maior ocorrência em áreas urbanas. Filtros de convolução foram aplicados em imagens dos sensores multiespectrais ENHANCE THEMATIC MAPPER Plus (ETM+) do satélite Landsat7, Haute Resolution Geometrique (HRG) do satélite SPOT 5 e os sensores IKONOS e QUICKBIRD.

Souza e Kux (2005) discutem a importância do conhecimento do comportamento espectral de alvos em ambientes urbanos para determinar o potencial de discriminação desses alvos pelo sensor CCD do satélite CBERS. Os autores utilizaram uma área de um bairro no município de São José dos Campos que se mostrou representativa por reunir os materiais utilizados com maior frequência nas coberturas residenciais e comerciais brasileiras.

Figura 1: Comportamento espectral de materiais comumente encontrados em ambientes urbanos.

Fonte: Sousa e Kux (2005)

A metodologia proposta foi composta por três etapas: coleta de dados, pré-processamento e processamento. Para um melhor entendimento dos resultados os autores apresentaram uma breve descrição das características dos materiais estudados. Apresentam também três justificativas da importância e necessidade de medir a refletância espectral dos alvos naturais e artificiais que são: a ampliação do

entendimento da relação entre a refletância espectral e os diferentes tipos de superfícies; avaliação do potencial de detecção das diferentes bandas espectrais para um alvo específico; avaliação do desempenho dos sistemas sensores comparando dados levantados em campo com os obtidos pelos sistemas sensores.

O trabalho de Souza e Kux (2005) é de grande importância, pois apresenta o comportamento espectral de alvos urbanos mais comumente encontrados no Brasil, o que subsidia uma série de outros trabalhos na análise do ambiente urbano mais ajustado à realidade brasileira. Observam que em imagens de alta resolução espacial o conhecimento do comportamento espectral é menos relevante, pois o reconhecimento dos alvos é feito pela forma, textura e arranjo espacial e não espectralmente.

3. MORFOLOGIA URBANA E INTRAURBANA

A morfologia urbana trata do estudo da forma do meio físico urbano, os processos de sua gênese e desenvolvimento e os atores envolvidos nesses processos. É um estudo interdisciplinar de grande valor aos planejadores e gestores urbanos. A forma física da cidade está condicionada por fatores culturais, sociais, econômicos e políticos.

Existem diversas teorias e correntes de pensamento no estudo da morfologia urbana, mas o que é comum para todas as vertentes é que a sociedade imprime suas características sociais, econômicas e políticas na forma da cidade, ou seja, a partir do arranjo físico da cidade é possível inferir como sua população se organiza.

O tecido urbano é composto por uma gama de elementos diversos, muitas vezes próprios a eles, como, sistema viário, edificações, praças, parques, enfim, pode possuir as mais diversas configurações. E as diversas configurações que uma cidade pode apresentar são o principal objeto de estudo da morfologia urbana. *“O tecido urbano é configurado pelo sistema viário, pelo padrão do parcelamento do solo, pela aglomeração e pelo isolamento das edificações assim como pelos espaços livres. Em outras palavras, o tecido de cidade é dado pelas edificações, ruas, quadras e lotes, parques, praças e monumentos, nos seus mais variados arranjos.”* (Rego, 2011).

Brito e Quintanilha (2013) discutem conceitos e elementos da morfologia urbana a fim de avaliar se a forma urbana, mesmo de áreas precárias, é passível de ser identificada com uso de produtos e técnicas de Sensoriamento Remoto utilizando imagens QUICKBIRD e fotografias aéreas de áreas do município de Salvador.

Apresentam um quadro comparativo com diversas formas de cidades encontradas em diferentes partes do mundo, ou seja, algumas das várias formas de distribuição espacial dos elementos que normalmente estão presentes nos cenários urbanos, como por exemplo, ruas pavimentadas, lote, quadra, entre outros.

Figura 2: Exemplos de configurações espaciais urbanas. Fonte: Brito e Quintanilha (2013)

Destacam que o uso de imagens de alta resolução e de fotografias aéreas são ferramentas importantes e eficazes para estudos de ambientes urbanos já que favorecem a identificação de elementos chave da morfologia da cidade.

- MORFOLOGIA INTRA-URBANA

Muitos trabalhos que tratam do uso do Sensoriamento Remoto em análises urbanas se dedicam a identificar e caracterizar padrões urbanos através da forma e da distribuição espacial dos elementos que compõem este ambiente, ou seja, através

da morfologia urbana e mais precisamente da morfologia intra-urbana quando a análise espacial é realizada a partir de uma imagem de alta resolução espacial.

De acordo com Villaça (1998) “o estudo da estrutura intra-urbana não será satisfatório se não der conta das localizações dos elementos da estrutura nem das correlações entre eles e outros elementos e/ou partes da metrópole.”

Um conceito importante nos estudos de morfologia intra-urbana é o de segregação, que é um processo no qual diferentes grupos sociais, por motivos diversos, tendem a se concentrar em uma determinada área mais do que em qualquer outra.

Muitas vezes essa segregação significa uma estratificação social e que acaba por se materializar no espaço (Villaça,1998), essa afirmação norteou os trabalhos de Souza et al. (2007) que a partir de um mapa de uso e ocupação do solo, retirou amostras de quadras residenciais para análise de seus atributos com o objetivo de estabelecer uma relação entre o padrão residencial e a situação socioeconômica da população residente.

Para isso levou em consideração elementos como: organização das quadras, arborização das ruas e dos terrenos, tamanho e ocupação do terreno, traçado e tratamento do sistema viário, densidade de ocupação, homogeneidade dos materiais dos telhados e acabamentos das residências. A análise orientada a objeto apresentou confusão entre as classes, porém a vegetação como um forte indicador socioeconômico definiu a separação das classes.

Souza et al. (2009) apresentam a avaliação da correlação entre os elementos presentes em um mapa de cobertura do solo intra-urbano e sua utilização para caracterização de áreas habitadas por população de baixa, média e alta renda usando como área de estudo 20% das quadras residenciais da cidade de São José dos Campos.

A metodologia proposta utilizou imagem QUICKBIRD de maio de 2004 e os programas e-Cognition, Spring e TerraView. As seguintes classes estavam contidas no mapa de cobertura do solo utilizado: vegetação, tipos de telhados (metálico, concreto amianto, telha cerâmica), piscina, sombra, asfalto e solo.

Foi denominado descritor, o conjunto de atributos que descrevem cada classe, após a definição dos limites desses descritores aliado ao conhecimento da área que os

autores têm, foi possível verificar a distribuição dos diferentes segmentos populacionais. As características de ocupação da classe média e baixa apresentaram erros de omissão e inclusão o que sinalizou a necessidade de estudos mais aprofundados dessa metodologia.

Outro tópico encontrado durante a revisão bibliográfica é o que relaciona a forma da cidade e o tipo de transporte utilizado preferencialmente por seus habitantes, Amâncio e Sanches (2005) modelaram as variáveis que medem a forma urbana considerando as características socioeconômicas e a distância a ser percorrida em cada viagem. Os resultados obtidos mostram que a opção pela caminhada se dá com maior probabilidade em locais em que há maior diversidade de usos do solo e alto índice de permeabilidade, que significa a qualidade do desenho das vias para os pedestres.

Em sua dissertação de mestrado, Souza (2003) utilizou imagens de alta resolução espacial e da análise intra-urbana como uma alternativa de estimativa populacional no intervalo dos censos oficiais.

4. GEOESTATÍSTICA

A Geoestatística foi concebida inicialmente para o estudo da distribuição espacial de minerais na avaliação de jazidas de ouro do Rand, África do Sul e teve Daniel Krige (1951) como precursor da técnica, Krige concluiu que somente a informação dada pela variância da concentração de ouro não explicaria o fenômeno, seria necessário levar em consideração a distância entre as amostras, desta maneira surge o conceito de geostatística, a qual considera a localização geográfica e a dependência espacial do fenômeno em estudo. (Camargo e Fucks, 2001)

A Geoestatística tem o objetivo de caracterizar a distribuição e a variabilidade espacial de uma variável de interesse, (Yamamoto e Landim, 2013)

George Matheron (1971) desenvolveu a teoria das variáveis regionalizadas, ou seja, as variáveis têm dependência espacial e podem ser modeladas, o que significa dizer que pontos próximos entre si são mais similares do que pontos distantes entre si (Van Der Meer, 2012).

Uma variável regionalizada é entendida como uma única realização de uma função casual, possuindo dependência espacial com uma distribuição e variação espacial, com uma continuidade aparente e que não pode ser prevista por uma função determinística (Yamamoto e Landim, 2013).

4.1. VARIOGRAMA

4.1.1 Conceitos iniciais

O variograma $2\gamma(\mathbf{h})$ é a esperança matemática do quadrado da diferença entre os valores localizados no espaço, separados por uma distância $\mathbf{h}$. Ou seja, representa quantitativamente a variação espacial de um fenômeno regionalizado em uma dada distância.

Ao considerar duas variáveis regionalizadas X e Y , onde $X = Z(x)$ e $Y = Z(x+h)$, as quais referem-se ao mesmo atributo, ou seja, são observações de um mesmo

fenômeno, mas medidos em duas localizações diferentes, tem o nível de dependência representado pelo variograma.

$$2\gamma(\mathbf{h}) = E\{[Z(\mathbf{x}) - Z(\mathbf{x} + \mathbf{h})]^2\} = \text{Var}[Z(\mathbf{x}) - Z(\mathbf{x} + \mathbf{h})] .$$

O variograma é utilizado como ponto de partida de muitos estudos espaciais, como por exemplo, métodos de estimação como a krigagem (Woodcock et al., 1988). A função variograma relaciona a variância à separação espacial e fornece uma concisa e imparcial descrição da escala e padrão da variabilidade espacial (Curran, 1998).

Variogramas medem a variação espacial através de variáveis regionalizadas, qualquer variável aleatória que apresenta uma posição no tempo ou no espaço é conhecida como uma variável regionalizada. O variograma caracteriza a distribuição espacial da variável regionalizada (Woodcock et al., 1988).

Recentemente o variograma tem sido utilizado para representar formalmente a dependência espacial em imagens de Sensoriamento Remoto e usado na classificação de texturas, Atkinson e Lewis (2000) utilizaram o variograma na classificação de uso e ocupação do solo em uma imagem de satélite tanto como uma medida de textura, quanto como um guia para a escolha da função suavização.

4.1.2 Parâmetros de um variograma

A figura 3 apresenta um variograma experimental típico com patamar e suas propriedades. O variograma expressa o aumento da variância com o incremento da distância na amostragem (Yamamoto, 2002), ou seja, é esperado que as diferenças entre os dados aumentem à medida que a distância entre eles aumenta, desta maneira, $\gamma(\mathbf{h})$ aumenta com a distância h .

Figura 3: Variograma típico e suas propriedades. Fonte: Yamamoto (2002)

- **Patamar (C_0+C)** é o parâmetro que revela a estabilização da variância entre as amostras.
- **Alcance ou amplitude (α)** é a distância a partir da qual as amostras passam a ser independentes, ou seja, esse parâmetro mostra quão homogêneas são as amostras entre si. Quanto maior a amplitude, maior a homogeneidade entre as amostras e a medida que a distância (**h**) vai aumentando essa homogeneidade vai diminuindo. É a amplitude que define o limite entre o campo estruturado, onde as amostras apresentam correlação, e o campo aleatório, onde as amostras são independentes.
- **Efeito Pepita ou variância aleatória (C_0)** é a descontinuidade junto à origem, fruto da amostragem (inadequação da amostra).

Em um campo aleatório isotrópico a variação é a mesma em todas as direções, enquanto que em um campo anisotrópico a variação difere com a direção. Variogramas podem ser calculados independentemente da orientação dos pares de pontos utilizados – isto se chama variograma omnidirecional, ou com uma determinada direção - variograma direcional.

Para determinação do variograma experimental é preciso saber se as amostras a serem analisadas estão distribuídas de forma regular (figura 4) ou irregular (figura 5).

Figura 4: Amostras distribuídas regularmente. Fonte: Camargo e Fucks (2001)

Figura 5: Amostras distribuídas irregularmente. Fonte: Camargo e Fucks (2001)

As amostras da presente pesquisa são regularmente espaçadas em duas dimensões, a figura 6 apresenta um exemplo das amostras analisadas nesse trabalho.

Figura 6: Exemplo de um dos conjuntos de amostras, com distribuição regular utilizados nesta pesquisa. Fonte: Barros, 2015

Esta é uma informação importante pois para determinar o variograma experimental nas quatro direções básicas (0° , 45° , 90° e 135°) significa que o cálculo de $\gamma(\mathbf{h})$ é repetido para todos os intervalos de h , ou seja, dada uma distância entre uma amostra e outra (4m no caso desse estudo), todos os pares que tiverem essa mesma distância serão incluídos no cálculo da primeira distância, e esse processo será repetido para a próxima distância (8m) e assim sucessivamente para as próximas distâncias como demonstra a figura 7.

Figura 7: Desenho esquemático de cálculo do variograma a partir de amostras regularmente distribuídas. Fonte: Camargo e Fucks (2001)

Os modelos teóricos são modelos que representam a tendência de $\gamma(h)$ em relação à distância, esses modelos são calculados a partir dos parâmetros do variograma, alcance, patamar e efeito pepita. Quanto melhor ajustado o modelo, mais exatas serão as estimativas obtidas a partir da krigagem. (Camargo e Fucks, 2001)

A figura 8 apresenta os modelos teóricos isotópicos básicos e suas respectivas equações.

Figura 8: Modelos teóricos de ajuste de variograma. Fonte: modificado de ESRI.

O procedimento de ajuste do modelo é iterativo, cabe ao interprete encontrar o ajuste ideal, ou seja, escolher o modelo que o intercepte maior número de pontos possível.

Ao se calcular os variogramas para as diferentes direções (0° , 45° , 90° , 135°) e observar que existe semelhança entre eles, considera-se que a distribuição espacial do fenômeno é isotrópica e neste caso apenas um modelo teórico é ajustado para descrever a variabilidade espacial.

Quando os variogramas não são iguais em todas as direções, considera-se que a distribuição espacial do fenômeno analisado é anisotrópica (figura 9).

Figura 9: Desenho esquemático do fenômeno espacial isotrópico. Fonte: Yamamoto e Landim (2013)

Variogramas com mesmo patamar e alcances diferentes indicam anisotropia geométrica (figura 10).

Figura 10: Desenho esquemático do fenômeno espacial anisotrópico. Fonte: Yamamoto e Landim (2013)

4.1.3 Mapas variográficos

Mapas variográficos são representações gráficas da anisotropia geométrica em duas dimensões, a elipse é calculada através dos valores de alcance obtidos em diferentes direções.

A elipse é a representação gráfica (figura 11) do fator ângulo da anisotropia geométrica. Ela é calculada através dos alcances obtidos em direções distintas. Para o eixo maior da elipse, denominado direção máxima de continuidade, aplica-se o maior alcance. O ângulo da direção de máxima continuidade é definido a partir da direção Norte e no sentido horário. O eixo menor define o alcance na direção de menor continuidade, sendo este ortogonal à direção principal. Mais detalhes em Camargo (1997).

Figura 11: Representação da anisotropia geométrica. Fonte: Camargo (1997)

4.2. GEOESTATÍSTICA E SENSORIAMENTO REMOTO APLICADOS AOS ESTUDOS EM AMBIENTES URBANOS

A geoestatística considera os números digitais de uma imagem digital como variável regionalizada que apresenta características como aleatoriedade e correlação espacial (Silva et al. 2011).

Van Der Meer (2012) apresenta uma revisão do atual estado da arte, de como a geoestatística é usada em estudos de sensoriamento remoto através do levantamento do que foi publicado nessa área entre os anos de 2000 e 2010. Destaca algumas aplicações, como por exemplo, o uso de variogramas para quantificar estrutura de imagem, textura e para otimização de escala de observação. Além de discorrer sobre outras ferramentas geoestatísticas como krigagem, co-krigagem e simulação estocástica.

Ainda de acordo com Van Der Meer (2012) dois avanços notáveis do uso da Geoestatística em Sensoriamento Remoto foram: o uso de variogramas e estimadores de krigagem e técnicas de simulação para mapeamento de super-

resolução e o uso de simulação e outras técnicas para definir esquemas ótimos de amostragem para relacionar a imagem ao dado de campo.

Muitas são as aplicações da geoestatística nos estudos de Sensoriamento Remoto. Esta seção apresenta essas diversas aplicações de acordo com a literatura consultada.

Curran e Atkinson (1998) trazem exemplos de aplicações da Geoestatística em Sensoriamento Remoto como, por exemplo, explorar e descrever a variabilidade espacial, aperfeiçoar o esboço de esquemas de amostragem em imagens além de aumentar a acurácia de classificações de uso e ocupação do solo.

Brivio e Zilioli (2001) apresentam uma revisão sobre o que já fora feito nesse campo até a data da publicação ao artigo. Fazem uma distinção entre textura (variação da frequência tonal) e padrão (arranjo espacial dos componentes texturais) e apresentam duas aproximações teóricas de variogramas bidirecionais que chama de variogramas multidirecionais e matriz de variogramas.

Wu et al. (2006) utilizam uma análise de textura baseada em variogramas a partir de fotografias aéreas infravermelhas digitais coloridas.

Lourenço e Landim (2003) fazem uso da geoestatística, através da krigagem ordinária, para modelar a variabilidade espacial de níveis de cinza de uma imagem de satélite, como o objetivo de minimizar os ruídos resultantes das sombras topográficas e assim gerar um mapa de índice de vegetação por diferença normalizada (NDVI). Apontam, ainda, que os níveis de cinza de uma imagem indicam a variabilidade local ou global dos elementos alvos e que existe uma dependência espacial associada à estrutura de cada classe de cobertura do solo.

Foi na década de 1980 que os primeiros trabalhos de Geoestatística, aplicada aos estudos de Sensoriamento Remoto, surgiram quando vários estudos usaram a análise de variogramas para quantificar estrutura de imagens (Van Der Meer, 2012).

De acordo com a literatura consultada, a maior parte dos trabalhos que tratam de Geoestatística e Sensoriamento Remoto, aplicados em estudos urbanos, trabalha a questão da heterogeneidade do ambiente urbano no qual a identificação de texturas é o principal objeto de análise.

No entanto, outros temas também podem ser encontrados, como por exemplo, o de Millward (2011) investiga a utilidade da variografia para estudos de detecção de mudanças em regiões que sofreram rápida urbanização. A constatação é que o variograma atendeu satisfatoriamente a habilidade de fornecer informações úteis para a identificação de mudanças, como por exemplo, o aumento da heterogeneidade.

Garrigues et al. (2008) quantificam a heterogeneidade espacial capturada pela banda do vermelho e infravermelho próximo de imagens de alta resolução usando variogramas diretos e cruzados.

4.3. O CONCEITO DE TEXTURA EM IMAGENS DE SENSORIAMENTO REMOTO

Em imagens de Sensoriamento Remoto, a configuração espacial de uma cidade é na verdade um conjunto intrincado de diversos usos e ocupações da superfície o que confere um tipo de textura para cada um deles. A textura é uma característica importante para a análise de uma série de tipos de imagem, especialmente as imagens de alta resolução espacial (Huang et al., 2008).

As texturas são padrões visuais que se repetem e que acabam por formar áreas homogêneas, ou seja, a textura varia espacialmente e isso pode indicar diferentes classes (Atkinson e Lewis, 2000).

A textura de uma imagem é descrita pelo número de tipos de seus elementos primários e pela organização desses elementos. Os elementos primários, os quais Kurkdjian (1988) se refere, no caso de áreas residenciais, significam áreas com residências grandes apresentam texturas diferentes de áreas com residências pequenas, assim como casas térreas ou prédios, ocupação densa ou esparsa, presença ou ausência de vegetação.

A tese de doutorado de Kurkdjian (1987) utilizou a textura urbana para a identificação de setores homogêneos que correspondem a agrupamentos humanos com características semelhantes, ou seja, a homogeneidade é o resultado da repetição de certo número de formas em um conjunto de arranjos espaciais que se reproduz.

Muitos dos trabalhos encontrados na literatura consultada utilizam medidas de textura para classificação de cobertura do solo, em grande parte desses trabalhos a análise de textura é combinada a outros métodos de classificação mais tradicionais com o objetivo de aumentar a acurácia da classificação.

Chica-Olmo e Abasrca-Hernández (2000) afirmam que algoritmos de classificação geralmente não consideram a dependência espectral entre o pixel e seus vizinhos, ou seja, não consideram a autocorrelação espacial. Esta dependência espacial deve ser considerada e pode ser quantificada e incorporada ao processo de classificação, desta maneira, apresentam uma metodologia de medição de texturas calculadas para uma distância específica de uma vizinhança usando uma janela móvel de duas das mais representativas componentes principais. Os resultados mostraram que o método proposto pode auxiliar na resolução de confusões inter-classes e consequente aumento da acurácia ao ser comparado aos métodos mais comuns de classificação.

Li *et. al.* (2009) Propõem um método para avaliar a textura de não apenas uma, mas de todas as bandas de uma imagem multiespectral para caracterizar a autocorrelação entre todas as bandas. Utilizou como classificador o *Support Vector Machines* (SVMs) combinando as medidas de textura e os dados espectrais da imagem. Os resultados demonstraram que utilizar informações de textura melhoram cerca de 5 a 13,5% a precisão global da classificação. Na mesma linha Cheng e Li (2005) introduzem um novo método para calcular textura de imagem para várias bandas de uma só vez. Um variograma multivariado é adotado e interpretado como uma medida de distância. A imagem de textura produzida foi incorporada à classificação espectral. Os resultados indicaram que comparada à classificação espectral, a inclusão da textura gerada a partir de várias bandas ao mesmo tempo melhoram a acurácia na classificação.

Atkinson e Lewis (2000) apresentam uma revisão do uso do variograma para classificação de imagens, usando a informação espacial para obter dados de textura e traz também o uso da informação espacial para “suavizar” imprecisões que possam surgir na classificação de imagens utilizando a dependência espacial entre vizinhos para aproximar pixels que provavelmente são parecidos.

Wu et al. (2006) também apresentam o uso do variograma para obter imagens de textura para classificação detalhada de uso do solo em meio urbano. Os autores ressaltam que classificar o tecido urbano apenas a partir da informação espectral não é suficiente, pois este ambiente é muito heterogêneo e contém uma grande variedade de respostas espectrais, desta maneira a informação de textura é utilizada para complementar a informação espectral.

Durrieu *et. al.* (2005) apresentam a proposta e a avaliação de 23 novos parâmetros geoestatísticos sendo, oito parâmetros designados “gerais” que consistem na variância dos níveis de cinza dos pixels, oito parâmetros foram calculados usando os valores dos variogramas dos máximos valores do variograma. O *lag* que atingiu o primeiro dos máximos valores, bem como a média e a variância dos *lags* considerados foram usados no cálculo desses parâmetros, os outros sete parâmetros derivaram dos valores entre o primeiro e o segundo valor máximo. Os resultados mostram acurácia acima de 81% para seis classes de textura e acima de 85% para cinco classes. O variograma omnidirecional apresentou melhor performance em texturas homogêneas, o variograma direcional apresentou maior acurácia nas texturas que continham um padrão de nível de cinza com estrutura espacial, como o caso dos pomares de laranja. Barros e Sobreira (2008) utilizaram imagem de alta resolução espacial para identificação de padrões de texturas através de recortes do tecido urbano, sob a ótica dos conceitos de fractais e lacunaridade.

Barros e Amorim (2008) também utilizaram fragmentos urbanos para identificar variações nos padrões espaciais intra-urbanos através do algoritmo *DIFFERENTIAL BOX-COUNTING*, que em um primeiro momento não distinguiu bem os padrões o que fez com que os autores analisassem os subfragmentos das imagens selecionadas.

Balaguer-Beser et al. (2010) avaliam a utilidade da extração de textura a partir de um semivariograma experimental de objetos específicos em imagens para classificação de uso do solo em imagens de alta resolução espacial.

5. ÁREA DE ESTUDO

A bacia do Rio Cabuçu de Baixo foi escolhida como área de estudo desta pesquisa por possuir uma série consistente de dados e por ser representativa no que diz respeito aos diversos padrões de ocupação encontrados em uma cidade como São Paulo.

Essa bacia hidrográfica está localizada ao norte do município de São Paulo (figura 12), e possui uma área aproximada de 42 km² e é composta por vários córregos cujas nascentes estão ao norte, dentro do Parque Estadual da Cantareira. Este parque é um dos mais importantes remanescentes de Mata Atlântica do município de São Paulo e considerado pela UNESCO como reserva da biosfera, que ocupa 30% de toda a bacia.

Figura 12: Localização da área de estudo. Fonte: Barros (2004)

De maneira geral a bacia é constituída por relevo de morros e montanhas com grandes declividades na sua porção norte, que vai suavizando até alcançar na sua

porção final a planície aluvial do Rio Tietê (figura 13). A região de relevo acidentado, antiga zona rural, é justamente aquela com ocupação mais recente, caracterizada por invasões e ocupações desordenadas que provocam intenso desmatamento em áreas de risco geológico.

Na bacia existem aproximadamente 150 favelas, sendo 28 localizadas em áreas críticas de risco geotécnico, todas na porção norte da bacia (ATLAS, 2002).

Figura 13: Mapa de uso da Bacia do Rio Cabuçu de Baixo. Fonte: Barros (2004)

A região do Rio Cabuçu de Baixo tem parte de sua ocupação consolidada, notadamente nas cabeceiras, com um processo de urbanização acelerado e completamente desordenado. Os bairros como Vila Brasilândia, Parada de Taipas e

Vila Nova Cachoeirinha, entre outros, estão totalmente ou em grande parte dentro dessa bacia.

A bacia do Rio Cabuçu de Baixo pode ser dividida em cinco sub-bacia (figura 14): córrego Bananal, córrego Itaguaçu, córrego Guaraú, córrego do Bispo e Rio Cabuçu de Baixo (curso inferior).

Figura 14: Divisão da bacia do Rio Cabuçu de Baixo em sub-bacias. Fonte: Ono (2008)

Para o presente trabalho foi selecionada a sub-bacia córrego Bananal, como estudo de caso. Localizado à montante do rio Cabuçu de Baixo, afluente da margem direita do rio Tietê, possui metade da sua área urbanizada e a outra metade ocupada pelo Parque Estadual da Serra da Cantareira.

A área do córrego do Bananal apresenta, assim como toda a bacia, crescimento desordenado, ocupação densa e irregular e autoconstrução em suas margens e nas

encostas. A figura 15 apresenta um exemplo do tipo de ocupação encontrada nessa região.

Figura 15: Exemplo de uma das configurações encontradas na área analisada. Fonte: Barros (2004)

A heterogeneidade urbana na bacia pode ser verificada nos diversos tipos de ocupação encontrados no que se refere ao padrão das edificações (aglomeração, dimensão, forma), bem como no sistema viário, presença ou ausência de pavimentação, largura, ordenamento das vias (BARROS, 2004).

5.1. DESCRIÇÃO DAS CLASSES ANALISADAS

A classe “Conjuntos Residenciais” é formada principalmente por conjuntos habitacionais frutos de programas de habitação da prefeitura do município de São Paulo através da COHAB (Companhia Metropolitana de Habitação). Trata-se de moradias populares em condomínios de prédios de até quatro andares.

A classe “Ocupação Densa Regularizada”, que é caracterizada pela presença de áreas totalmente urbanizadas, altas taxas de impermeabilização do solo. O termo “regularizada”, utilizado aqui, se refere ao fato de que essas áreas foram regularizadas junto à prefeitura e não porque houve algum planejamento urbanístico para a demarcação dos lotes e de suas ruas, apenas assinala que as ruas e lotes já constam nos registros do órgão responsável.

A classe “Ocupação densa irregular” abrange uma área significativa da sub-bacia do córrego Bananal. Consiste na invasão de terrenos desocupados para formação de loteamentos irregulares, ou seja, sem a devida observância da legislação vigente e sem qualquer intervenção de agentes técnicos habilitados formando, desta maneira, um padrão de moradia típico de favelas ou habitações subnormais. As casas são fruto de autoconstrução e ocupam áreas de risco de inundação ou risco de deslizamentos, não possuem sistema de saneamento básico.

Outra característica importante dessa classe é o arruamento irregular ou clandestino, ou seja, ruas que não são reconhecidas ou aprovadas pelos órgãos públicos competentes. Essas vias são estreitas, apresentam ruas pavimentadas e não pavimentadas e não possuem ordenamento de quadras. O quadro 1 apresenta a sistematização das características básicas de cada classe e exemplos de como elas aparecem na imagem multiespectral.

Quadro 1 : Descrição das classes analisadas

Classe	Descrição	Imagem Multiespectral
<p>Conjuntos Residenciais</p>	<p>Classe formada por conjuntos habitacionais com prédios de até 4 andares em lotes amplos. O arruamento é ordenado e as vias são asfaltadas e largas.</p>
<p>Ocupação Densa Regularizada</p>	<p>Classe formada por casas em lotes que medem entre 6 e 10 metros de frente e 12 e 16 metros de fundo. O arruamento apresenta baixo ordenamento, as ruas são asfaltadas e alterna trechos de ruas estreitas e ruas largas.</p>
<p>Ocupação Densa Irregular</p>	<p>Classe formada por lotes que medem entre 4 e 6 metros de frente e 8 e 10 de fundo. O arruamento é pouco ordenado, apresenta ruas com e sem asfalto.</p>

6. MATERIAIS E MÉTODO

6.1. MATERIAIS

6.1.1. Imagem de satélite e mapa

Esta pesquisa utilizou uma cena de uma imagem orbital IKONOS II de 16 de outubro de 2002, adquiridas no modo CarterraGeo - Pancromática (PAN), com 1 metro de resolução e multiespectral (MSS) com 4 metros de resolução espacial (figura 16). O quadro 2 apresenta a ficha técnica com as principais informações sobre o satélite IKONOS 2.

Figura 16: Imagem IKONOS. Fonte: Nóbrega (2007)

Quadro2: Principais características do satélite IKONOS II.

Altitude	680 km
Inclinação	98,1º
Velocidade	7km / s
Sentido da Órbita	Descendente
Duração da Órbita	98 minutos
Tipo de Órbita	Sol-síncrona
Resolução Espacial	Pancromática: 1m / Multiespectral: 4m
Bandas espectrais	Pan 0.45 - 0.90 μ Azul 0.45 - 0.52 μ Verde 0.52 - 0.60 μ Vermelho 0.63 - 0.69 μ Infra vermelho próximo 0.76 - 0.90 μ
Imageamento	13km na vertical (cenas de 13km x 13km)
Capacidade de Aquisição de imagens	Faixas de 11km x 100km até 11km x 1000km Mosaicos de até 12.000km ² 20.000km ² de área imageada numa passagem
Frequência de Revisita	2.9 dias a 1m de resolução

Fonte:Engesat.

A resolução radiométrica dos sensores no satélite IKONOS II é de 11 bits (2048 níveis de cinza), o que permite uma melhor interpretação das imagens, se comparadas a uma imagem de 8 bits (256 níveis de cinza).

A fim de servir como ponto de partida para atender ao objetivo de identificar padrões de ocupação urbana foi utilizada a classificação de uso e ocupação do solo proposta pelo projeto Atlas Ambiental da Prefeitura Municipal de São Paulo (2002).

A figura 17 apresenta o mapa de uso e ocupação do solo com dezoito classes das quais três são referentes ao uso e ocupação residencial, a saber: conjuntos residenciais, ocupação densa irregular e ocupação densa regularizada.

O presente trabalho analisou as três classes supracitadas, que estão localizadas na porção oeste da Bacia do Rio Cabuçu de Baixo, mais precisamente na sub-bacia do córrego Bananal.

Figura 17: Mapa de uso e ocupação do solo com destaque para a sub-bacia do córrego Bananal.

Fonte: LGP/PTR/Polí/USP

A figura 18 apresenta a imagem IKONOS com os polígonos das classes a serem analisadas, extraídos do mapa de uso e ocupação do solo da bacia do Rio Cabuçu de Baixo, “Conjuntos Residenciais” em azul; “Ocupação Densa Irregular” em verde e “Ocupação Densa Regularizada” em amarelo.

Figura 18: Polígonos das classes analisadas sobrepostos à imagem IKONOS. Fonte: Barros (2014)

6.1.2. Programas

O *SPRING* 5.1.6. - Sistema de Processamento de Informações Georreferenciadas - é um SIG (Sistema de Informações Geográficas) com funções de processamento de imagens, análise espacial, modelagem numérica de terreno e consulta a banco de dados espaciais.

O *SPRING* foi utilizado nessa pesquisa para calcular a Componente Principal das quatro bandas da imagem de satélite.

O ArcGis 10 da empresa ESRI, que é um conjunto de programas que constitui um SIG (Sistemas de Informações Geográficas).

O processamento dos dados foi realizado no ArcMap que é o principal programa do ArcGis, que permite visualizar, editar, criar e analisar dados geoespaciais.

O ArcGIS foi utilizado nessa pesquisa para a preparação e seleção das amostras, bem como para a análise variográfica das mesmas.

6.2. MÉTODO PROPOSTO

O método proposto baseou-se no trabalho publicado no artigo de Barros et al. (2013) que teve o objetivo de caracterizar padrões de uso do solo através de parâmetros de variogramas, utilizando imagens do satélite QUICKBIRD do bairro Ferroviários em Salvador – Bahia, Brasil.

Além da área de estudo, outras etapas do método supracitado foram alterados, como por exemplo, tipo de imagem e modelo variográfico ajustado. O método proposto baseou-se nos seguintes processos: a partir da imagem de satélite foram calculadas as componentes principais e a partir do mapa de uso e ocupação do solo foram selecionados os polígonos a serem analisados; recorte das amostras de imagem das áreas de cada classe; seleção das amostras mais representativas de cada classe; cálculo dos variogramas e avaliação dos variogramas obtidos (figura 19). Os processos realizados estão detalhados no ANEXO I.

Figura 19: Fluxo simplificado do método utilizado. Fonte: Barros (2014)

A técnica de componentes principais foi aplicada sobre a matriz de variância e covariância dos quatro canais multiespectrais da imagem utilizando o programa SPRING 5.1.6.

“A covariância é uma grandeza que relaciona duas variâncias específicas e descreve o quanto a distribuição é espalhada ao longo da direção diagonal e, portanto, o grau de correlação existente entre duas bandas, ou seja, a covariância indica o quanto de informação contida em um par de bandas é comum a ambas” (Crosta, 1999)

A transformação por componentes principais funciona da seguinte maneira, dado um conjunto N (N_1 , N_2 , N_3 , N_4 ...) de imagens brutas, esse conjunto de imagens é analisado quanto à correlação existente entre elas e então um novo conjunto N de imagens é produzido. A primeira componente principal contém a informação que é comum a todas as bandas originais; a segunda componente contém a feição espectral mais significativa do conjunto. As próximas componentes apresentam as informações espectrais menos relevantes. A figura 20 apresenta a estatística das quatro componentes principais.

PI	Média	Variância
po_126532_blu_0000000	374.47	8435.01
po_126532_grn_0000000	416.02	20431.70
po_126532_nir_0000000	534.98	20238.93
po_126532_red_0000000	332.69	27787.70

PC	Auto-valor	Porcentagem
P1	57941.10	75.35
P2	17963.75	23.36
P3	804.70	1.05
P4	183.79	0.24

Matriz de Covariância			
8435.01	12717.95	2495.83	14356.01
12717.95	20431.70	5847.53	23398.79
2495.83	5847.53	20238.93	7022.80
14356.01	23398.79	7022.80	27787.70

Matriz de Correlação			
1.000	0.969	0.191	0.938
0.969	1.000	0.288	0.982
0.191	0.288	1.000	0.296
0.938	0.982	0.296	1.000

Matriz de Auto-vetores			
0.36	0.59	0.24	0.68
-0.15	-0.14	0.97	-0.15
-0.72	-0.27	-0.05	0.63
0.57	-0.75	0.03	0.33

Figura 20: Estatísticas da análise por Componentes Principais. Fonte: Barros (2014)

Onde,

1º autovalor = 57941.1 com 75.35% de toda a informação das 4 bandas originais

$$\mathbf{CP1} = 0.36B1(B) + 0.59B2(G) + 0.24B3(N) + 0.68B4(R)$$

2º autovalor = 17963.75 com 23.36% de toda a informação das 4 bandas originais

$$\mathbf{CP2} = -0.15B1(B) - 0.14B2(G) + 0.97B3(N) - 0.15B4(R)$$

3º autovalor = 804.7 com 1.05% de toda a informação das 4 bandas originais

$$\mathbf{CP3} = -0.72B1(B) - 0.27B2(G) - 0.05B3(N) + 0.63B4(R)$$

4º autovalor = 183.79 com 0.24% de toda a informação das 4 bandas originais

$$\mathbf{CP4} = 0.57B1(B) - 0.75B2(G) + 0.03B3(N) + 0.33B4(R)$$

A correlação entre bandas multiespectrais encobre diferenças sutis entre as refletâncias dos materiais dos alvos terrestres o que dificulta a diferenciação entre os mesmos. Essa correlação indica que uma imagem pode ser mais ou menos inferida a partir de outra, o que implica a existência de redundância dos dados. “Se uma grande proporção de cada banda espectral é composta por informação redundante, porque não extrair essa informação comum concentrando-a em uma única imagem ao invés de replicá-la várias vezes?” (CROSTA, 1999).

Dessa forma, a superfície univariada da primeira componente principal (CP1) foi utilizada neste trabalho nas etapas subsequentes, sendo considerada como representativa das superfícies construídas na região, uma vez que concentra grande parte das variações (~75%) existentes nas quatro bandas originais. Os polígonos obtidos pela classificação serviram para delimitar as áreas de onde seriam retiradas as amostras de imagem a serem analisadas. Desta maneira foram “recortadas” 10 amostras da primeira componente principal de cada classe analisada como exemplificado pela figura 21.

Conjuntos Residenciais	Ocupação Densa Regularizada	Ocupação Densa Irregular

Figura 21: Exemplo das amostras de CP1 de cada classe analisada.

Os quadros 3, 4 e 5 apresentam a estatística básica do conjunto de amostras de cada classe de uso do solo retiradas da Primeira Componente Principal.

Quadro 3: Estatística básica da classe “Conjuntos Residenciais”

PC1 - Conjuntos Residenciais	Contagem	Min.	Máx.	Média	Desvio Padrão
		15337	65534	39254,95	10320,35
Amostra 1	490	16331	64002	35828	8426,3
Amostra 2	488	18015	65534	39342	10106
Amostra 3	493	17473	65534	38885	10320
Amostra 4	491	19667	65534	41152	9835,7
Amostra 5	485	19450	65534	43586	10749
Amostra 6	487	18200	65534	39851	9717,6
Amostra 7	491	16942	65534	35102	8874,4
Amostra 8	490	18884	65534	36586	9667,2
Amostra 9	486	15337	65534	32987	8525,1
Amostra 10	492	17209	65534	43317	10160

Quadro 4: Estatística Básica da classe “Ocupação Densa Irregular”

PC1 – Ocupação Densa Irregular	Contagem	Min.	Máx.	Média	Desvio Padrão
		18956	635534	43620,19	9958,79
Amostra 1	121	20928	65534	41490	11417
Amostra 2	120	29380	65534	41520	7037
Amostra 3	121	26656	65534	47256	10214
Amostra 4	123	24482	65534	44007	9990,2
Amostra 5	123	27855	65534	46360	9333,2
Amostra 6	122	26578	65534	42901	9891,9
Amostra 7	122	26468	65534	46084	10086
Amostra 8	119	18956	65534	37202	10037
Amostra 9	123	27197	65534	43854	9009,8
Amostra 10	122	25649	65534	45319	8141,8

Quadro 5: Estatística Básica da classe “Ocupação Densa Regular”

PC1 – Ocupação Densa Regular	Contagem	Min.	Máx.	Média	Desvio Padrão
		20471	65534	43018,87	9842,87
Amostra 1	176	24833	35534	44843	9389,5
Amostra 2	175	20597	62443	39142	8320,5
Amostra 3	177	24023	65534	40938	9624,2
Amostra 4	179	22121	65534	42700	10390
Amostra 5	172	22730	65534	42238	9487,5
Amostra 6	177	22430	65534	42584	10413
Amostra 7	177	25183	65534	44940	8131,6
Amostra 8	174	28238	65534	46747	9729,2
Amostra 9	177	20471	65534	40407	9939,9
Amostra 10	177	23401	65534	45661	10111

Foi gerada uma malha de pontos (figura 22) com a informação do número digital de cada pixel e os variogramas foram então calculados.

Figura 22: Exemplo da malha de pontos com os valores digitais de cada pixel. Fonte: Barros (2014)

- GEOESTATISTICAL ANALYST

O módulo de análise geoestatística do ArcGis é composto por 3 principais componentes, exploração de dados, assistente geoestatístico e criação de subconjuntos.

Antes de implementar técnicas de interpolação, é importante conhecer os dados que serão analisados, o componente “exploração de dados” conta com ferramentas para análise exploratória de dados como, histograma, análise de tendência, variograma e nuvem de covariância, entre outros. O assistente geoestatístico funciona como um guia numa sequência de telas, onde é possível escolher e definir alguns parâmetros para o cálculo de variogramas e subsequente interpolação (krigagem e co-krigagem).

A criação de subconjuntos consiste em um método de avaliação da qualidade da superfície calculada após a interpolação. Esse componente permite a divisão do conjunto de dados em duas partes, uma que pode ser usada para modelar a estrutura espacial e produzir a superfície, e a outra parte pode ser usada para comparar e validar as previsões.

7. RESULTADOS E DISCUSSÕES

Os valores dos parâmetros dos variogramas, bem como o mapa variográfico, a imagem multiespectral e a primeira componente principal das 10 amostras de cada amostra foram sistematizados nos quadros 6, 7 e 8.

Quadro 6: Sistematização dos resultados da classe “Conjuntos Residenciais”

CONJUNTOS RESIDENCIAIS				
Parâmetros	Variogramas	Mapa Vario gráfico	Imagem Multiespectral	Componente Principal 1
Amostra1 Alcance= 26 Patamar= 5×10^7 Efeito Pepita= 0
Amostra2 Alcance= 48 Patamar= 5×10^7 Efeito Pepita= 4
Amostra3 Alcance= 25 Patamar= 11×10^7 Efeito Pepita= 0
Amostra4 Alcance= 25 Patamar= 8×10^7 Efeito Pepita= 3
Amostra5 Alcance= 26 Patamar= 10×10^7 Efeito Pepita= 3
Amostra6 Alcance= 28 Patamar= 9×10^7 Efeito Pepita= 7
Amostra7 Alcance= 48 Patamar= 6×10^7 Efeito Pepita= 2
Amostra8 Alcance= 27 Patamar= 9×10^7 Efeito Pepita= 4
Amostra9 Alcance= 13 Patamar= 7×10^7 Efeito Pepita= 0
Amostra10 Alcance= 22 Patamar= 10×10^7 Efeito Pepita= 3

Quadro 7: Sistematização dos resultados da classe “Ocupação Densa Regularizada”

OCUPAÇÃO DENSE IRREGULAR				
Parâmetros	Variogramas	Mapa Vario gráfico	Imagem Multiespectral	Componente Principal 1
Amostra 1 Alcance= 19 Patamar= 11×10^7 Efeito Pepita= 2
Amostra 2 Alcance= 21 Patamar= 28×10^7 Efeito Pepita= 2
Amostra 3 Alcance= 22 Patamar= 10×10^7 Efeito Pepita= 0
Amostra 4 Alcance= 24 Patamar= 8×10^7 Efeito Pepita= 3
Amostra 5 Alcance= 10 Patamar= 9×10^7 Efeito Pepita= 0
Amostra 6 Alcance= 24 Patamar= 9×10^7 Efeito Pepita= 4
Amostra 7 Alcance= 9 Patamar= 10×10^7 Efeito Pepita= 0
Amostra 8 Alcance= 12 Patamar= 10×10^7 Efeito Pepita= 0
Amostra 9 Alcance= 13 Patamar= 8×10^7 Efeito Pepita= 3
Amostra 10 Alcance= 24 Patamar= 6×10^7 Efeito Pepita= 1

Quadro 8: Sistematização dos resultados da classe “Ocupação Densa Irregular”

OCUPAÇÃO DENSE REGULARIZADA				
Parâmetros	Variogramas	Mapa Vario gráfico	Imagem Multiespectral	Componente Principal 1
Amostra 1 Alcance= 28 Patamar= 5×10^7 Efeito Pepita= 4×10^7
Amostra 2 Alcance= 28 Patamar= 4×10^7 Efeito Pepita= 3×10^7
Amostra 3 Alcance= 11 Patamar= 9×10^7 Efeito Pepita= 5×10^7
Amostra 4 Alcance= 13 Patamar= 7×10^7 Efeito Pepita= 3×10^7
Amostra 5 Alcance= 12 Patamar= 8×10^7 Efeito Pepita= 0
Amostra 6 Alcance= 15 Patamar= 10×10^7 Efeito Pepita= 8×10^7
Amostra 7 Alcance= 10 Patamar= 5×10^7 Efeito Pepita= 2×10^7
Amostra 8 Alcance= 15 Patamar= 6×10^7 Efeito Pepita= 3×10^7
Amostra 9 Alcance= 16 Patamar= 6×10^7 Efeito Pepita= 3×10^7
Amostra 10 Alcance= 24 Patamar= 8×10^7 Efeito Pepita= 3×10^7

A elipse apresentada nos mapas variográficos sugerem anisotropia na maioria das amostras. É interessante observar que a direção preferencial da variância acompanha a orientação dos elementos dispostos no terreno (figura 23), no entanto

os variogramas não foram calculados nas quatro direções básicas, pois esta pesquisa não tem o objetivo de estimar, apenas o de identificar padrões a partir do comportamento espectral.

Figura 23: Exemplo de como direção preferencial da variância coincide com a orientação dos elementos da imagem. Fonte: Barros (2014)

Os resultados foram sistematizados no Quadros 9, 10 e 11, nos quais estão os valores dos parâmetros dos variogramas, Alcance, Patamar e Efeito Pepita de cada amostra. Os valores estão em notação científica (10^7) para facilitar a interpretação.

Quadro 9: Valores dos parâmetros “Conjuntos Residenciais”

Conjuntos Residenciais			
	Alcance	Patamar ($\times 10^7$)	Efeito Pepita ($\times 10^7$)
Amostra 1	26	7	0
Amostra 2	48	5	4
Amostra 3	25	11	0
Amostra 4	25	8	3
Amostra 5	26	10	3
Amostra 6	28	9	7
Amostra 7	48	6	2
Amostra 8	27	9	4
Amostra 9	13	7	0
Amostra 10	22	10	3

Quadro 10: Valores dos parâmetros “Ocupação Densa Regularizada”

Ocupação Densa Regularizada			
	Alcance	Patamar ($\times 10^7$)	Efeito Pepita ($\times 10^7$)
Amostra 1	28	5	4
Amostra 2	28	4	3
Amostra 3	11	9	5
Amostra 4	13	7	3
Amostra 5	12	8	0
Amostra 6	15	10	8
Amostra 7	10	5	2
Amostra 8	15	6	3
Amostra 9	16	6	3
Amostra 10	24	8	3

Quadro 11: Valores dos parâmetros “Ocupação Densa Irregular”

Ocupação Densa Irregular			
	Alcance	Patamar ($\times 10^7$)	Efeito Pepita ($\times 10^7$)
Amostra 1	19	11	2
Amostra 2	21	28	2
Amostra 3	22	10	0
Amostra 4	24	8	3
Amostra 5	10	9	0
Amostra 6	24	9	4
Amostra 7	9	10	0
Amostra 8	12	10	0
Amostra 9	13	8	3
Amostra 10	24	6	1

O alcance é o parâmetro mais importante para o tipo da análise desse estudo, pois é esse parâmetro que define o grau de homogeneização, quanto maior a amplitude, maior a homogeneidade entre as amostras (ou seja, os níveis de cinza dos pixels têm uma similaridade maior entre eles). Desta maneira este trabalho considerou apenas os valores de alcance na análise, os demais parâmetros serão analisados em trabalhos futuros. O quadro 12 apresenta a estatística descritiva básica dos resultados obtidos para o parâmetro alcance no cálculo dos variogramas.

Quadro 12: Estatística descritiva básica dos valores de alcance das classes”

Estatística descritiva básica	Conjuntos Residenciais	Ocupação Densa Regularizada	Ocupação Densa Irregular
Alcance			
Média	29	17	18
Erro padrão	3	2	2
Mediana	26	15	20
Desvio padrão	11	7	6
Variância da amostra	120	47	38
Curtose	1	-1	-2
Assimetria	1	1	0
Mínimo	13	10	9
Máximo	48	28	24
Soma	288	172	178
Contagem	10	10	10

Ao analisarmos os valores de alcance nas três classes de amostras e o valor de média de cada delas vemos que as classes “Ocupação Densa Regularizada” e “Ocupação Densa Irregular” apresentam médias bastante próximas, com 17 e 18 respectivamente, enquanto que a média dos valores de alcance das amostras da classe “Conjuntos Residenciais” se destaca das demais com 29.

A classe “Conjuntos Residenciais” a qual possui características bastante particulares quanto às suas propriedades, como, por exemplo, tamanho do terreno, formato das construções, materiais utilizados, bem como a organização espacial das construções seguem em sua maioria um determinado padrão e acabam por conferir a essa classe uma textura que a torna homogênea entre as demais.

A figura 24 representa alguns exemplos da classe “Conjuntos Residenciais” em que é possível observar que há uma repetição de características que conferem homogeneidade na textura da mesma. As construções seguem um alinhamento, com espaços regulares entre as construções, intercalando áreas construídas e sombras também de maneira bastante regular, bem como a forma alongada e estreita das construções e os materiais utilizados.

Figura 24: Repetição de padrões da classe “Conjuntos Residenciais”

Recorrendo ao histórico de ocupação da área de estudo é possível entender porque, embora classificadas como duas classes distintas, as classes “Ocupação densa regularizada” e “Ocupação densa irregular” apresentam médias de valores de alcance tão próximas a ponto de o variograma não conseguir distingui-las com maior precisão.

Diferente dos conjuntos residenciais que foram planejados, com uma área reservada para a construção dos mesmos, somadas às características supracitadas, as outras duas classes apresentam como principal característica a autoconstrução e a ocupação desordenada, ou seja, qualquer planejamento.

Embora algumas características diferenciem uma classe da outra, como por exemplo, o tamanho dos lotes, maiores na classe “Ocupação Densa Regularizada” e o padrão de arruamento apresentando maior ordenamento e maior largura também na classe “Ocupação Densa Regularizada” em diversos trechos essa diferença não é tão clara. A figura 25 mostra como é possível confundir as duas classes tanto quanto a forma das construções, sua configuração espacial, os materiais utilizados e o padrão de arruamento.

Figura 25: Comparação de algumas amostras das classes “Ocupação Densa Regular” e “Ocupação Densa Irregular”. Fonte: Barros (2014)

A classe “Ocupação Densa Regularizada” é formada por lotes que foram regularizados posteriormente à ocupação da área, ou seja, não houve um planejamento para que aquela área fosse ocupada para fins residenciais. Da mesma maneira ocorre na classe “Ocupação Densa Irregular”, que representa uma área que foi ocupada sem nenhum tipo de ordenamento e que ainda não teve seus lotes e ruas regulamentados pelos órgãos competentes.

8. CONCLUSÕES

O Sensoriamento Remoto exerce um papel muito importante na aquisição de informações sobre a organização espacial dos elementos terrestres nas mais diferentes escalas e tipos de ambiente.

As imagens de satélite de alta resolução espacial apoiam principalmente estudos em ambientes urbanos, pois esse tipo de imagem permite uma maior apreensão do tecido urbano já que é capaz de distinguir com maior precisão os objetos que compõem o cenário urbano bastante heterogêneo.

A dinâmica de crescimento das cidades é alvo de inúmeros estudos e áreas do conhecimento, conhecer os mecanismos envolvidos nesse processo é de vital importância para gestores e planejadores urbanos já que a população urbana apresenta crescimento constante e megacidades não param de surgir em todo mundo. O presente trabalho vai ao encontro da temática supracitada ao analisar a proposta metodológica de identificar padrões de organização urbana através da ferramenta geoestatística, o variograma.

Analisar padrões residenciais urbanos é de grande importância para gestão e planejamento das cidades no que tange o acesso à moradia, aos serviços públicos como transporte, saúde, educação, saneamento básico e energia elétrica, assim como emprego e lazer, já que a identificação desses padrões permite visualizar de que modo a cidade se organiza e um aprofundamento desse tipo de estudo pode inferir em que direção a cidade está crescendo.

No caso dessa pesquisa, a identificação dos padrões residenciais urbanos foi realizada a partir do comportamento espectral das classes analisadas, ao analisar as diferenças entre os padrões é possível inferir outras informações a respeito das características daquela área. A diferença do comportamento espectral entre as classes residenciais se dá pelos diferentes materiais, tamanhos e formas das construções encontradas em cada classe.

Uma consequência da identificação de padrões é a delimitação do espaço intra-urbano em setores homogêneos, a princípio, uma homogeneidade referente aos aspectos físicos supracitados, em uma análise mais aprofundada esses padrões podem refletir também os aspectos socioeconômicos da população residente.

Em posse das características físicas e socioeconômicas dessa localidade é que planejadores e gestores urbanos podem propor estratégias de urbanização para a cidade.

Embora essa pesquisa tenha alcançado resultados satisfatórios, a proposta metodológica analisada apresentou uma série de pontos a serem revistos e testados em trabalhos futuros para garantir sua replicabilidade.

Uma das dificuldades encontradas durante a pesquisa foi obter uma imagem de alta resolução que não tivesse passado por nenhum tipo de correção ou fusão, já que para analisar a variância espacial do comportamento espectral dos alvos é necessário que o dado seja o mais “bruto possível”.

Embora seja possível encontrar padrões homogêneos no tecido urbano e intra-urbano das cidades, em determinados aspectos os padrões encontrados apresentam heterogeneidade entre si, ou seja, no caso da classe “ocupação densa irregular” que pode ser qualificada como favela ou como habitação subnormal, existem inúmeros exemplares deste tipo de organização habitacional, que utilizam diferentes materiais na construção das moradias, bem como se distribuem espacialmente de maneiras diversas.

A questão é que as classes trabalhadas no presente estudo, com exceção da classe “conjuntos residenciais”, que é bem definida, e que conseguiu ser detectada pelos parâmetros dos variogramas calculados, as outras duas classes são visivelmente e espectralmente muito próximas o que fez com que os variogramas não distinguíssem claramente uma da outra.

Essa “confusão” entre as classes pode ser reflexo do processo de ocupação de toda a área de estudo, ou seja, mesmo a área que hoje é considerada “regularizada”, já foi no passado considerada uma ocupação “irregular” evidenciando que não houve nenhum tipo de planejamento habitacional para a área de estudo.

De acordo com os resultados obtidos, conclui-se que a proposta metodológica atingiu seu objetivo ao identificar áreas homogêneas em imagens de satélite de alta resolução, no entanto observou-se que ela se aplica melhor em áreas que apresentam classes bem definidas, ou seja, no presente trabalho, a classe “Conjuntos Residenciais” foi claramente identificada pelos variogramas por possuir características e configuração bastante singular, já as outras duas classes

analisadas “Ocupação Densa Regularizada” e “Ocupação Densa Irregular” apresentam características, configurações e materiais construtivos bastante semelhantes entre si o que fez com que a identificação dessas classes via variograma não fosse tão eficaz.

A proposta de avaliar espectralmente imagens de alta resolução espacial através da geoestatística pode ampliar o leque de métodos de classificação de imagens de Sensoriamento Remoto, pois essa técnica atua em um aspecto pouco explorado em imagens de alta resolução espacial que são os valores pixel a pixel. O aprimoramento desta técnica poderá trazer contribuições importantes como técnica de validação de métodos de classificação assim como fornecendo valores de input para classificações de uso e ocupação do solo.

A metodologia proposta provou ser válida e pode ainda ser uma ferramenta rápida e de baixo custo para planejadores urbanos que precisam, por exemplo: caracterizar a morfologia da cidade. Pode ser aplicada para analisar imagens de satélite; detectar classes que não separáveis nas condições regulares das imagens; ajudar a selecionar um conjunto de amostras de treinamento para aplicação em algoritmos de classificação supervisionada; dimensionamento de regras ou variáveis externas em OBIA (como o tamanho buffer), escala do modelo digital de terreno, e assim por diante.

9. REFERÊNCIAS BIBLIOGRÁFICAS

ALVARENGA, L.H.V. **Imagens de alta resolução e geoestatística na estratificação da fisionomia cerrado para inventários florestais**. 2012. 91 f. Dissertação (Mestrado em Engenharia Florestal). Universidade Federal de Lavras, Lavras, 2012.

AMÂNCIO, M.A.; SANCHES, S. P. Relacionamento entre a Forma Urbana e as viagens a pé. In: **Anais de Congresso da Associação Nacional de Pesquisa e Ensino em Transportes – XIX ANPET**, 2005, Recife – PE. XIX ANPET, 2005.

ANTUNES, A. F. B.; DUARTE, A. Characterization of the growth of urban areas by means of QUICKBIRD images through object oriented segmentation. In: **Proceedings of the 4th GEOBIA**, Rio de Janeiro, 2012.

ALVES, R. A. L.; VERGARA, O. R. Identificação de alvos urbanos em imagens IKONOS, aplicando classificação orientada a segmentos. In: XII Simpósio Brasileiro de Sensoriamento Remoto, 2005, Goiânia, GO. **Anais do XII Simpósio Brasileiro de Sensoriamento Remoto**, São José dos Campos, 2005. p. 2573-2580

ATKINSON, P.M.; LEWIS, P. Geostatistical classification for remote sensing: an introduction. **Computers & Geosciences**, v. 26, n. 4, p. 361-371, 2000.

ATLAS. Atlas Ambiental do Município de São Paulo. São Paulo, SP, 2002. Disponível em <<http://atlasambiental.prefeitura.sp.gov.br>>.

BALAGUER-BESER, A.; RUIZ, L. A.; HERMOSILLA, T.; RECIO, J. A. Definition of a comprehensive set of texture semivariogram features and their evaluation for object-oriented image classification. **Computers & Geosciences**, v.36, p. 231-240. 2010.

BALAGUER-BESER A.; RUIZ, L.A.; HERMOSILLA, T.; RECIO, J.A. Using semivariogram indices to analyse heterogeneity in spatial patterns in remotely sensed images. **Computers & Geosciences**, v.50, p.115-127, 2013.

BARROS M.T.L (Org.). **Gerenciamento Integrado de Bacias Hidrográficas em Áreas Urbanas** - Sistema de Suporte ao Gerenciamento da Água Urbana - Estudo de Caso: Rio Cabuçu de Baixo, Cidade de São Paulo. São Paulo: Escola Politécnica da USP e CNPq, 2004.

BARROS, M.T.L. (Org.). **Plano de Bacia Urbana**: Relatório Final. CT-HIDRO, EPUSP/PHD, São Paulo, 2005.

BARROS, D.; BRITO, P.L.; LAROCCA, A.P.; GIANNOTTI, M.A.; SHINOHARA, E.J.; KOLLING, J.; HO, L.L.; QUINTANILHA, J.A. Characterizing urban land use pattern by variograms parameters from multispectral high spatial resolution satellite images: an application in Salvador, Bahia - Brazil. In: **Proceedings of Geoscience and Remote Sensing Symposium (IGARSS)**, Melbourne – Australia, 2013. pp. 3309-3312.

BARROS FILHO, M. N. M.; AMORIM, L. Texturas urbanas e distinções morfológicas. In: **II Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação**, 2008, Recife, PE. 2008. v. 1.

BARROS FILHO, MAURO, and SOBREIRA F.. 2008. Accuracy of lacunarity algorithms in texture classification of high spatial resolution images from urban areas. *The International Archives of the Photogrammetry, Remote Sensing, and Spatial Information Sciences* 37: 417-22.

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

BRITO, P.L.; QUINTANILHA J.A. A literature review, 2001-2008, of classification methods and inner urban characteristics identified in multispectral remote sensing images. In: **Proceedings of 4th GEOBIA**, Rio de Janeiro, Brazil, p. 586-591, 2012.

BRITO P.L.; QUINTANILHA, J.A. Elementos da morfologia urbana de ocupações urbanas informais em imagens de sensoriamento remoto. In: TEIXEIRA, A.N.; ALENCAR, C.M.M.; CARVALHO, S.S. (Org.). **Desafios Contemporâneos de Dinâmicas Territoriais e Socioambientais**. Curitiba: Editora CRV, p. 169-188, 2013.

BRIVIO, P.A.; ZILIOLI, E. Urban pattern characterization through geostatistical analysis of satellite images. In: DONNAY, J.P. BARNESLEY, M.J.; LONGLEY, P.A. (eds.), **Remote Sensing and Urban Analysis**, Taylor and Francis; London, 2001, pp. 40–53.

CAMARGO, E.C.G. **Desenvolvimento, implementação e teste de procedimentos geoestatísticos (krigagem) no sistema de Processamento de Informações Georreferenciadas (SPRING)**. São José dos Campos: INPE, 1997.

CAMARGO, E.C.G.; FUCKS, S.D. Geoestatística: fundamentos e aplicações. In CÂMARA, G. Geoprocessamento: teoria e aplicações. Disponível em: <http://www.dpi.inpe.br/gilberto/livro> > acesso em jun. 2013.

CHICA-OLMO, M., HERNÁNDEZ-ABARCA, F. Computing geostatistical image texture for remotely sensed data classification. **Computers & Geosciences**, v.26, p. 373-383, 2000.

CHENG, T. L.; LI, P. Multivariate variogram-based multichannel image texture for image classification. In Geoscience and Remote Sensing Symposium, 2005. **Proceedings...** v. 6, 2005.p.3830 – 3832.

CROSTA, A.P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: UNICAMP. 1999.

CURRAN, P.J. The Semivariogram in Remote Sensing: An Introduction. **Remote Sensing of Environment**. 24, n. 3, p.493-507, 1998.

CURRAN P.J., ATKINSON, P.M. Geostatistics and Remote Sensing. **Progress in Physician Geography**, v. 22, n. 1, p. 61-78, 1998.

DONAY, J. P, BARNESLEY, R, LONGLEY, P.A. Of patterns and processes: spatial metrics and geostatistics in urban analysis. In A. Smith and B. Jones (Eds) Remote sensing and urban analysis (pp.93). London, UK: Taylor & Francis. 2001.

DURRIEU, M., RUIZ, L.A., BALAGUER, A. Analysis of geostatistical parameters for texture classification of satellite images. In 25th EARSEL Symposium: Global Developments in Environmental Earth Observation from Space. **Proceedings...** 2005. pp. 11-18

DURIEUX, L.; LAGABRIELLE, E. ; NELSON, A. A method for monitoring building construction in urban sprawl areas using object-based analysis of Spot 5 images and existing GIS data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 63, n.4,p. 399-408, 2008.

ESCH, T.; TAUBENBÖCK, H.; FELBIER, A. , HELDENS, M.; WIESNER, M.; DECH,S. Monitoring of Global Urbanization – Time Series Analyses for Mega Cities Based on Optical and SAR Data. In: **Proceedings of Second International Workshop on Earth Observation and Remote Sensing Applications**, Shanghai, China, p. 21-25, 2012.

GARRIGUES, S., ALLARD, D., BARET, F., MORISETTE, J. Multivariate quantification of landscape spatial heterogeneity using variogram models. **Remote Sensing of Environment**, v.112, p. 216-230, 2008.

GIANNINI MB, MEROLA P AND ALEGRINI A (2012) Texture analysis for urban areas classification in high resolution satellite imagery. *Applied Remote Sensing Journal*, 2(2): 65-71.

HEROLD, M.; GARDNER, M.; HADLEY, B.; ROBERTS, D. The spectral dimension in urban land cover mapping from high-resolution optical remote sensing data. In: **Third International Symposium Remote Sensing of Urban Areas**, Istanbul, 2002.

HUANG, Y., et al. Texture feature extraction for land-cover classification of remote sensing data in land consolidation district using semi-variogram analysis. **WSEAS Transactions on Computers**, 2008.

ISAAKS, E.H.; SRIVASTAVA, R.M. **An Introduction to Applied Geostatistics**. Oxford University Press, 1990.

JAT, M.K.; GARG, P.K.; KHARE, D. Monitoring and modelling of urban sprawl using remote sensing and GIS techniques. **International Journal of Applied Earth Observation and Geoinformation**, v. 10, n. 1, p. 26-43, 2008.

KIT, O.; LÜDEKE, M.; RECKIEN, D. Texture-based identification of urban slums in Hyderabad, India using remote sensing data. **Applied Geography**, v. 32, p. 660 – 667, 2012

KOCHHAN, R.; GLEYZES, D. Future Mobility in Tropical Megacities. In: Sustainable Automotive Technologies 2012: In: 4th International Conference, Ed. SUBIC, A.; WELLNITZ, J.; LEARY, M. and KOOPMANS, L. **Proceedings...** Springer, Berlim, 2012.

KUFFER, M.; BARROS, J. Urban morphology of unplanned settlements: the use of spatial metrics in VHR remotely sensed images. **Procedia Environmental Science**, v. 7, p. 152-157, 2011.

KURKDJIAN, M. L. N. O. **Um Método para a Identificação e Análise de Setores Residenciais Urbanos Homogêneos através de dados de Sensoriamento Remoto com Vistas ao Planejamento Urbano**. 1987. Tese de Doutorado. Faculdade de Arquitetura e Urbanismo, Universidade de São Paulo, São Paulo, 1987.

KURKDJIAN, M. L. N. O. Homogeneous Photographic Texture: An Instrument to Identify Different Urban Population Segments. **International archives of photogrammetry and remote sensing**, v.27, p. 327-327, 1988.

LEÃO, D. Z. **Análise da textura para mapeamento da precariedade habitacional**. 2011. 118 f. Dissertação (Mestrado em Planejamento Urbano e Regional). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

LI, P.; CHENG, T.; GUO, J. Multivariate image texture by multivariate variogram for multispectral image classification. In: **Photogrammetric Engineering & Remote Sensing**, v.75, n. 2, 2009. p. 147 -157.

LOURENÇO, R. W., LANDIM, P. M. B. Tratamento de imagem de satélite por meio de metodologia geoestatística. **Revista Universidade Guarulhos: Geociências** (Impresso), Guarulhos, v. 6, p. 20-35, 2003.

MACHADO, C.A.S.; BELTRAME, A.M.K.; SHINOHARA, E.J.; GIANNOTTI, M.A., DURIEUX, L., NÓBREGA, T.M.; QUINTANILHA, J.A. Identifying concentrated areas of trip generators from high spatial resolution satellite images using object-based classification techniques. **Applied Geography**, 53:271-283,2014.

MILLWARD A. A. Urbanization viewed through a geostatistical lens applied to remote-sensing data. **Area**, v.43, n. 1, p. 53-66, 2011.

NOBREGA, R.A.A. Detecção da malha viária na periferia urbana de São Paulo utilizando imagens orbitais de alta resolução espacial e classificação orientada a objetos. 2007. 157f. Tese (Doutorado em Engenharia de Transportes) – Escola Politécnica, Universidade de São Paulo, 2007.

NÓBREGA, R.A.A.; O'HARA, C.G.; QUINTANILHA, J.A. Detecting roads in informal settlements surrounding Sao Paulo city by using object-based classification. In: **Proceedings of 1st International Conference on Object-Based Image Analysis**, 2006.

NÓBREGA, R.A.A.; O'HARA, C.G.; QUINTANILHA, J.A. An object-based approach to detect road features for informal settlements near Sao Paulo, Brazil. In: **Object-based image analysis**, Springer Berlin Heidelberg, p. 589-607, 2008.

NOVO, E.M.L.M. **Sensoriamento remoto: princípios e aplicações**. 4.ed São Paulo: Blucher, 2010.

PACIFICI F, CHINI M AND EMERY WJ (2009) A neural network approach using multi-scale textural metrics from very high-resolution panchromatic imagery for urban land-use classification. *Remote Sensing of Environment*, 113: 1276-1292.

PATINO, J.E. ; DUQUE, J.C. A review of regional science applications of satellite remote sensing in urban settings. **Computers, Environment and Urban Systems**, v. 37, p. 1–17, 2013.

PINHO, C.M.D.; KUX, H.J.H.; ALMEIDA, C.M. Influência de Diferentes Padrões de Ocupação na Qualidade de Mapeamentos de Cobertura do Solo em Imagens de Alta Resolução Espacial: Estudo de Caso de São José dos Campos (SP). In: BLASCHKE, T.; KUX, H. (Org). **Sensoriamento Remoto e SIG Avançados: Novos Sistemas Sensores, Métodos Inovadores**. São Paulo: Oficina de Textos, 2005. p. 198-208.

PINHO, C.M.D.; UMMUS, M.E.; NOVACK, T. Simulação do comportamento espectral de alvos urbanos em sensores multiespectrais. In: Simpósio Brasileiro de Sensoriamento Remoto, 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 803-810.

PINHO, C.M.D., FONSECA, L.M.G.; KORTING, T.S.; ALMEIDA, C.M.; KUX, H.J.H. Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis. **International Journal of Remote Sensing**, v. 33, n.19, p. 5973-5995, 2012.

QUINTANILHA J.A. ; SILVA, O.F. Identification of urban objects through IKONOS images. In: J. C. N. Epiphany, & L. M. G. Fonseca (Eds.). **Anais do XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, 2005.

QUINTANILHA J.A.; O'HARA, C.G.; NOBREGA, R.A.A. Detecção de vias em áreas na periferia de São Paulo através de classificação em imagens orbitais baseada em objetos. In: **Anais do XX ANPET** - Congresso de Pesquisa e Ensino em Transportes. Brasília, 2006. p.679-690.

REGO R. L. ; MENEGUETTI, K. S. A respeito de morfologia urbana. Tópicos básicos para estudos de forma da cidade, **Acta Scientiarum: Technology**. Maringá, v. 33, p. 123-127, 2011.

RIDD, M.K. Exploring a V-I-S (vegetation-impervious surface-soil) model for urban ecosystem analysis through remote sensing: comparative anatomy for cities. **International Journal of Remote Sensing**, v.16, n.12, p.2165-2185, 1995.

SALIM, A. **Caracterização do uso da terra em periferias urbanas utilizando geotecnologias - bacia do Reservatório Guarapiranga**. Dissertação (Mestrado em Geografia Física) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 2013.

SCHWARZ, N. Urban form revisited – Selecting indicators for characterizing European cities. **Landscape and Urban Planning**, v. 96, n.1,p. 29-47, 2010.

SILVA, A. F., BARBOSA, A. P., ZIMBACK, C. R. L.,LANDIM, P. M. B.Classificadores de imagens por técnicas de sensoriamento remoto e geoestatística. In: II Simpósio de Geoestatística Aplicada em Ciências Agrárias, 2011, Botucatu, SP. **Anais do II Simpósio de Geoestatística Aplicada em Ciências Agrárias**, 2011. p. 1-5.

SOUZA, I.M. **Análise do espaço intra-urbano para estimativa populacional intercensitária utilizando dados orbitais de alta resolução espacial**. 2003. 104 p. Dissertação (Mestrado em Planejamento Urbano e Regional) – Universidade do Vale do Paraíba, São José dos Campos, 2003.

SOUZA, R. C. A. ; KUX, H. J. H. Comportamento espectral de Alvos urbanos: simulação com as bandas espectrais do satélite CBERS. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 2005, Goiânia. p. 1099-1106.

SOUZA, I.M.; ALVES, C.D.; ALMEIDA, C.M.; PINHO, C.M.D. Caracterização Socioeconômica do Espaço Residencial Construído Utilizando Imagens de Alta Resolução Espacial e Análise Orientada a Objeto. **Geografia (Londrina)**, v.16, n.1, p. 119-142, 2007.

SOUZA, I.D.M.; ALVES, C.D.;ALMEIDA, C.M.;PINHO, C.M.D. Uso de imagens de alta resolução espacial e análise orientada a objeto para caracterização socioeconômica do espaço residencial construído. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 14. Natal, 2009. pp. 875-882.

SUDHIRA, H.S.; RAMACHANDRA, T.V.; JAGADISH, K. S. Urban sprawl: metrics, dynamics and modeling using GIS. **International Journal of Applied Earth Observations and Geoinformation**, v.5, n.1, p. 29-39, 2004.

TAUBENBÖCK, H.; ESCH, T.; FELBIER, A.; WIESNER, M.; ROTH, A.; DECH.S. Monitoring urbanization in mega cities from space. **Remote Sensing of Environment**, v. 117, p. 162–176, 2012.

TEWOLDE MG.AND CABRAL P (2011). Urban sprawl analysis and modeling in Asmara, Eritrea. *Remote Sensing*, 3(10): 2148-2165.

VIEIRA, I.M; CANDEIAS. A. L. B.; SANTOS, A.C.; HAMBURGUER, D. S. **Utilização de processamento digital de imagens na delimitação de áreas urbanas**.

Trabalho apresentado à disciplina de Processamento digital de imagens durante o curso de mestrado em sensoriamento remoto no INPE. São José dos Campo, 1989.

VILLAÇA, F. **Espaço Intra-Urbano no Brasil**. São Paulo: Studio Nobel: FAPESP: Lincoln Institute, 1998.

VAN DER MEER, F. Remote-sensing image analysis and geostatistics. **International Journal of Remote Sensing**, v. 33, n. 18, p.5644–5676, 2012.

YAMAMOTO J.K. **Curso de Geoestatística Aplicada**. São Paulo: USP/LIG/ABGE, 2002.

YAMAMOTO, J.K.; LANDIM, P.M.B. Geoestatística: Conceitos e Aplicações. São Paulo, Oficina de textos, 2013, 216p.

WANG, L.; LI C.C.; YING, Q.; CHENG, X.; WANG, X.Y.; LI X.Y., HU L.Y.; JIANG L.; YU L.; HUANG , H.B.; CONG, O. China's Urban Expansion from 1990 to 2010 Determined with Satellite Remote Sensing. **Chinese Science Bulletin**, v. 57, n. 22, p. 2802-2812, 2012.

WENG Q (ed.). **Remote sensing of impervious surfaces: An overview**. Boca Raton: CRC Press Taylor & Francis Group, 2008.

WOODCOCK, C.E.; STRAHLER, A.H.; JUPP, D.L.B. The use of variograms in Remote Sensing: I. Scene Models and Simulated Images. **Remote Sensing of Environment**, v. 25, n.3, p. 323 – 348 ,1988.

WU,S.S.; B. XU; WANG, L. Urban land-use classification using variogram-based analysis with an aerial photograph. **Photogrammetric Engineering & Remote Sensing**, v. 72, n.7, p.813-822, 2006.

ANEXO I

A técnica componente principal (figura 1) foi aplicada sobre a matriz de variância e covariância dos quatro canais multiespectrais da imagem utilizando o *software* SPRING 5.1.6. A primeira componente principal foi então exportada como arquivo. TIFF para ser trabalhada no *software* ArcGIS.

Figura 1: Cálculo das componentes principais e exportação para arquivo. TIFF.

A Primeira Componente Principal foi então exportada para o *software* ArcGIS 10, assim como os polígonos das três classes analisadas. (figura 2)

Figura 2: Primeira componente principal com os polígonos das classes analisadas

O *software* ArcGis 10 da empresa ESRI, é um conjunto de programas que constitui um SIG (Sistemas de Informações Geográficas). O processamento dos dados foi realizado no ArcMap que é o principal programa do ArcGis, que permite visualizar, editar, criar e analisar dados geoespaciais.

No ARCGIS 10, os polígonos foram convertidos em linha (figura 3) para posterior criação de um buffer de 10m (figura 4), que após algumas tentativas se mostrou a medida que melhor atendeu ao objetivo de criar uma margem de segurança em torno dos polígonos de cada classe, ou seja, para garantir que os polígonos não fossem “contaminados” por elementos que não pertencessem à sua classe.

Figura 3: Transformação dos polígonos em linhas.

Figura 4: *Buffer* de 10m.

Os polígonos das classes foram sobrepostos à imagem e através da ferramenta *Eraser* a imagem foi então recortada de acordo com os limites dos polígonos. (Figura 5)

Figura 5: A imagem foi recortada de acordo com o polígono da classe.

Para definir as amostras a ferramenta *Feature to Point* foi utilizada para determinar o centroide de cada polígono das classes (Figura 6), esse procedimento garante que a amostra seja retirada do centro do polígono, e que a mesma esteja completamente dentro do polígono da classe.

Figura 6: Centroide de cada polígono.

A partir de cada centroide foi calculado um tamanho de buffer diferente de acordo com o tamanho do fenômeno analisado, ou seja, na classe “Conjuntos Residenciais” (Figura 7) foi calculado um buffer de 100 metros de diâmetro, esta classe é composta basicamente por conjuntos habitacionais formados por vários prédios de até 4 andares, portanto, ocupando áreas maiores.

Figura 7: Amostras da classe “Conjuntos Residenciais”

Na classe “Ocupação Densa Regularizada” (Figura 8) foi calculado um buffer de 60 metros de diâmetro já que as construções dessa classe estão em lotes que medem entre 6 e 10m de frente e 12 e 16m de fundo.

Figura 8: Amostras da classe “Ocupação Densa Regularizada”

A classe “Ocupação Densa Irregular” (Figura 9) foi calculado um buffer de 50 metros de diâmetro, esta medida foi escolhida por caber inteiramente em muitos polígonos da classe e por abranger uma representativa porção dos alvos dessa classe, que apresentam construções em lotes entre 4 e 6m de frente e entre 8 e 10m de fundo.

Figura 9: Amostras da classe “Ocupação Densa Irregular”

Após análise visual das classes foram eleitas 10 amostras de cada classe de modo que cada uma delas apresentasse o maior número de características correspondentes a cada classe no intuito de deixar a amostragem o mais representativa possível.

A ferramenta *Extract by Mask* (figura 10) foi utilizada para recortar a imagem da primeira componente principal a partir do buffer de cada amostra.

Figura 10: Exemplos dos fragmentos da imagem da Primeira Componente Principal utilizados para o cálculo dos variogramas.

Através da ferramenta *Feature to Point* as imagens das amostras foram convertidas em uma malha de pontos (Figura 11), onde cada ponto representa o nível de cinza de cada pixel.

Figura 11: Transformação *Feature to Point*.

Com a amostragem definida foram calculados os variogramas através da extensão *Geostatistical Analyst* do ArcGis10.

O *Geostatistical Analyst* (Figura 12) é uma extensão do ArcGis que fornece um conjunto de modelos estatísticos e ferramentas para exploração de dados espaciais e geração de superfície. Com essa ferramenta é possível:

- Explorar a variabilidade dos dados e suas relações espaciais examinar tendências globais e locais;
- Utilizar análise multivariada para criar modelos estatísticos para produzir mapas de previsão confiáveis;
- Modificar os parâmetros do modelo de forma interativa ou otimizá-los automaticamente utilizando a validação cruzada;
- Determinar os locais ideais para criar ou implantar uma rede de monitoramento, entre outras aplicações.

Figura 12: *Geostatistical Wizard* é uma extensão do *Geostatistical Analyst* onde os variogramas foram calculados.

Os variogramas foram calculados sobre os níveis de cinza da primeira componente principal de cada uma das amostras selecionadas. O modelo que apresentou o melhor ajuste foi o esférico, adotado para todas as amostras.

Na classe “Conjuntos Residenciais” foram utilizados 12 *lags* de 4m (*lag size*). “Ocupação Densa Regularizada” foram utilizados 7 *lags* de 4m (*lag size*); na classe “Ocupação Densa Irregular” foram utilizados 6 *lags* de 4m (*lag size*) e na classe