

**Análise comparada da classificação “*pixel a pixel*” e orientada por  
objecto de uma imagem *WorldView 2* de Maputo, Moçambique**

**Joana Filipa Rodrigues Piçarra**

**Trabalho de Projecto de Mestrado em Gestão do Território  
Área de Especialização em Detecção Remota e Sistemas de  
Informação Geográfica**

**Março, 2014**

Trabalho de Projecto apresentado para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Gestão do Território, na área de especialização em Detecção Remota e Sistemas de Informação Geográfica, realizado sob a orientação científica do Professor Doutor José António Tenedório e da coorientação científica da Professora Doutora Cristina Delgado Henriques.

Declaro que este Relatório é o resultado da minha investigação pessoal e independente.  
O seu conteúdo é original e todas as fontes consultadas estão devidamente mencionadas no texto, nas notas e na bibliografia.

O candidato,

---

Joana Filipe Rodrigues Piçarra

Lisboa, 31 de Março de 2014

Declaro que este Relatório se encontra em condições de ser apreciado pelo júri a designar.

O orientador,

A co-orientadora,

---

José António Tenedório

---

Cristina Delgado Henriques

Lisboa, 31 de Março de 2014

*Dedico este Trabalho de Projecto à minha família,  
por todo o apoio, encorajamento e compreensão ao  
longo do meu percurso de vida.*

## AGRADECIMENTOS

Ao Professor Doutor José António Tenedório, por ter aceitado orientar-me e por ter sido o primeiro a despertar o meu interesse por esta temática. Obrigada por toda a disponibilidade, por todo o apoio e partilha de saber, quer na realização do presente trabalho de projecto, quer durante todo o meu percurso académico na UNL-FCSH.

À Professora Doutora Cristina Delgado Henriques da Faculdade de Arquitectura da UL, por gentilmente me ter cedido a sua experiência, pela transmissão do conhecimento do terreno da área em estudo e pela disponibilização da imagem de satélite *WorldView 2*.

Obrigada aos meus pais, sem o apoio deles a realização deste trabalho de projecto não seria possível. Obrigada por todo o amor, apoio incondicional, compreensão e dedicação. Obrigada por terem sempre acreditado em mim.

Aos meus amigos, por me acompanharem em mais uma etapa da minha vida. Por estarem sempre presentes e por serem quem são.

À Rita Coutinho e à Cláudia Mota, por todo o apoio e por serem as melhores amigas de sempre.

MUITÍSSIMO OBRIGADA A TODOS!

# ANÁLISE COMPARADA DA CLASSIFICAÇÃO “PIXEL A PIXEL” E ORIENTADA POR OBJECTO DE UMA IMAGEM *WORLDVIEW 2* de Maputo, Moçambique

Joana Filipa Rodrigues Piçarra

## RESUMO

**PALAVRAS-CHAVE:** Detecção Remota, Imagem de Alta Resolução, Algoritmos de Classificação, Pixel, Orientada por Objecto

O desenvolvimento das tecnologias associadas à Detecção Remota e aos Sistemas de Informação Geográfica encontram-se cada vez mais na ordem do dia. E, graças a este desenvolvimento de métodos para acelerar a produção de informação geográfica, assiste-se a um crescente aumento da resolução geométrica, espectral e radiométrica das imagens, e simultaneamente, ao aparecimento de novas aplicações com o intuito de facilitar o processamento e a análise de imagens através da melhoria de algoritmos para extracção de informação. Resultado disso são as imagens de alta resolução, provenientes do satélite *WorldView 2* e o mais recente *software Envi 5.0*, utilizados neste estudo.

O presente trabalho tem como principal objectivo desenvolver um projecto de cartografia de uso do solo para a cidade de Maputo, com recurso ao tratamento e à exploração de uma imagem de alta resolução, comparando as potencialidades e limitações dos resultados extraídos através da classificação “*pixel a pixel*”, através do algoritmo Máxima Verossimilhança, face às potencialidades e eventuais limitações da classificação orientada por objecto, através dos algoritmos *K Nearest Neighbor* (KNN) e *Support Vector Machine* (SVM), na extracção do mesmo número e tipo de classes de ocupação/uso do solo.

Na classificação “*pixel a pixel*”, com a aplicação do algoritmo classificação Máxima Verossimilhança, foram ensaiados dois tipos de amostra: uma primeira constituída por 20 classes de ocupação/uso do solo, e uma segunda por 18 classes. Após a fase de experimentação, os resultados obtidos com a primeira amostra ficaram aquém das expectativas, pois observavam-se muitos erros de classificação. A segunda amostra formulada com base nestes erros de classificação e com o objectivo de os minimizar, permitiu obter um resultado próximo das expectativas idealizadas inicialmente, onde as classes de interesse coincidem com a realidade geográfica da cidade de Maputo.

Na classificação orientada por objecto foram 4 as etapas metodológicas utilizadas: a atribuição do valor 5 para a segmentação e 90 para a fusão de segmentos; a selecção de 15 exemplos sobre os segmentos gerados para cada classe de interesse; bandas diferentemente distribuídas para o cálculo dos atributos espectrais e de textura; os atributos de forma *Elongation* e *Form Factor* e a aplicação dos algoritmos *KNN* e *SVM*. Confrontando as imagens resultantes das duas abordagens aplicadas, verificou-se que a qualidade do mapa produzido pela classificação “*pixel a pixel*” apresenta um nível de

detalhe superior aos mapas resultantes da classificação orientada por objecto. Esta diferença de nível de detalhe é justificada pela unidade mínima do processamento de cada classificador: enquanto que na primeira abordagem a unidade mínima é o *pixel*, traduzindo uma maior detalhe, a segunda abordagem utiliza um conjunto de *pixels*, objecto, como unidade mínima despoletando situações de generalização. De um modo geral, a extracção da forma dos elementos e a distribuição das classes de interesse correspondem à realidade geográfica em si e, os resultados são bons face ao que é frequente em processamento semiautomático.

# **A COMPARATIVE ANALYSIS OF CLASSIFICATION "PIXEL BY PIXEL" AND OBJECT ORIENTED AN IMAGE WORLDVIEW 2 OF MAPUTO, MOZAMBIQUE**

**Joana Filipa Rodrigues Piçarra**

## **ABSTRACT**

**KEYWORDS:** Remote Sensing, High Resolution Image, Classification Algorithms, Pixel, Object Oriented

The development associated with Remote Sensing and GIS technologies are increasingly on the agenda. And thanks to this development of methods to accelerate the production of geographic information, we are witnessing an increasing geometric, spectral and radiometric resolution of the images, and simultaneously, the emergence of new applications in order to facilitate processing and analysis images through improved algorithms for extracting information. Results are the high resolution images, from the WorldView 2 satellite and the latest Envi 5.0 software, used in this study.

This work aims to develop a draft land use maps for the city of Maputo, using the processing and exploitation of a high resolution image, comparing the strengths and limitations of the extracted results by classifying "pixel pixel", by maximum likelihood, given the potential and possible limitations of object-oriented classification algorithm, using algorithms K Nearest Neighbor (KNN) and Support Vector Machine (SVM), the extraction of the same number and type of classes occupation/land use.

A first consists of 20 classes of occupancy/land use, and a second for 18 classes: in the classification "pixel by pixel" with the application of the Maximum Likelihood classification algorithm, two types of sample were tested. After the experimentation phase, the results obtained with the first sample fell short of expectations because we observed many misclassifications. The second sample made based on these classification errors and with the aim of minimizing the allowed obtain a result near the expectations initially envisioned where the classes of interest coincide with the geographical reality of Maputo.

In object oriented classification were 4 methodological steps used: the assignment of the value 5 to 90 for the segmentation and fusion of segments, the selection of 15 examples of the segments generated for each class of interest; bands distributed differently for the calculation of spectral and textural attributes, the attributes of form and Elongation Factor form and Application of KNN and SVM algorithms.

Comparing the images resulting from the two approaches applied, it was found that the quality of classification map produced by "one pixel" has a higher level of the resultant maps the object oriented classification detail. This difference in level of detail is explained by the first processing unit of each classifier: in the first approach while the pixel is the minimum unit translates greater detail, the second approach uses a set

of pixels, object, such as a unit triggering situations principle of generalization. In general, the shape of the extraction elements and the distribution of classes of interest correspond to the geographical reality itself, and the results are good compared to what is frequent in semiautomatic processing.

## ÍNDICE

<b>Capítulo I. Introdução e contextualização .....</b>	<b>1</b>
1.1.Introdução .....	1
1.2.Objectivo .....	4
1.3. Área de estudo .....	5
1.4.Dados .....	6
<b>Capítulo II. Metodologia.....</b>	<b>8</b>
2.1. Fusão de imagem.....	8
2.2. Nomenclatura proposta de classificação .....	10
2.2.1. Esquema síntese da nomenclatura proposta de classificação .....	13
2.3. Classificação “ <i>pixel a pixel</i> ” .....	14
2.3.1. Algoritmo de classificação máxima verossimilhança .....	16
2.4. Classificação orientada por objecto e segmentação de imagem.....	21
2.4.1. Segmentação de imagem - <i>Segment Only Feature Extraction</i> .....	22
2.4.2. Segmentação de imagem - <i>Example Based Feature Extraction</i> .....	25
2.4.2.1. Atributos espectrais .....	26
2.4.2.2. Atributos de textura .....	27
2.4.2.3. Atributos de forma .....	29
2.4.2.4. Algoritmo de classificação <i>K-Nearest Neighbor</i> .....	32
2.4.2.5. Algoritmo de classificação <i>Support Vector Machine</i> .....	35
2.5. Fluxograma .....	39
<b>Capítulo III. Resultados.....</b>	<b>40</b>
3.1. Resultado final da classificação “ <i>pixel a pixel</i> ” - Máxima Verossimilhança .....	42
3.2. Resultado da classificação orientada por objecto - <i>K Nearest Neighbor</i> .....	43
3.3. Resultado da classificação orientada por objecto - <i>Support Vector Machine</i> ....	44
3.4. Análise de concordância entre os resultados dos classificadores .....	45

3.4.1. Máxima Verossimilhança e <i>K Nearest Neighbor</i> .....	49
3.4.2. Máxima Verossimilhança e <i>Support Vector Machine</i> .....	50
3.4.3. <i>K Nearest Neighbor</i> e <i>Support Vector Machine</i> .....	51
3.4.4. Intersecção dos resultados dos diferentes classificadores .....	52
<b>Considerações Finais .....</b>	<b>53</b>
<b>Bibliografia .....</b>	<b>57</b>
<b>Índice de Figuras.....</b>	<b>60</b>
<b>Índice de Quadros .....</b>	<b>61</b>
<b>Anexos.....</b>	<b>62</b>

## LISTA DE ABREVIATURAS

%	Percentagem
cm	Centímetros
DR	Detecção Remota
ha	Hectares
km <sup>2</sup>	Quilómetro quadrado
KNN	<i>K Nearest Neighbor</i>
m	Metros
MV	Máxima Verossimilhança
nº	Número
PP	<i>Pixel a Pixel</i>
RMS	Erro médio quadrático ( <i>root mean square</i> )
SIG	Sistemas de Informação Geográfica
SVM	<i>Support Vector Machine</i>

## CAPÍTULO I. INTRODUÇÃO E CONTEXTUALIZAÇÃO

### 1.1. INTRODUÇÃO

Nos dias de hoje, verifica-se uma crescente utilização de informação proveniente de satélites. As imagens de satélite são um instrumento fundamental para que o geógrafo possa conhecer e compreender o espaço a distância e em diferentes épocas.

A imagem de satélite utilizada neste estudo incide sobre a maior cidade de Moçambique, a cidade de Maputo.

As cidades africanas crescem a um ritmo incontável, onde o processo de urbanização é recente e ocorre de forma intensa, e Maputo não é excepção. Estas mudanças e tendências urbanas podem ser observadas através do processamento de imagens de satélite.

Face a esta realidade, ciências como a Detecção Remota (DR) e ferramentas como os Sistemas de Informação Geográfica (SIG), que suportam as referidas imagens de satélite, desempenham um papel preponderante na observação de dinâmicas e mudanças no território.

São vários os autores que definem Detecção Remota. Segundo SABINS, (1996, *apud* CASIMIRO, 2002), “Detecção Remota define-se como a ciência de adquirir, processar e interpretar imagens e dados relacionados, obtidos de aviões e satélites, que registam a interacção entre matéria e radiação electromagnética.”

“Detecção Remota é um conjunto de conhecimentos e técnicas utilizadas para determinar as características físicas e biológicas de um objecto através de medidas feitas à distância, sem contacto material com o objecto. Meio de conhecer um objecto, ou um conjunto de objectos distribuídos espacialmente em função:

- De um ou vários sinais electromagnéticos numa ou várias bandas do comprimento de onda;
- Da evolução do sinal electromagnético do objecto no tempo;
- Da repartição de um objecto no espaço geográfico (Chorologia);

- Das ligações temporais do objecto com outros objectos de natureza diferenciada que o rodeiam ou que lhe são conexos.

A Detecção Remota aplicada é um conjunto de métodos e técnicos necessários para interpretar diversos objectos através do seu comportamento espectral e distribuições espaciais recorrendo a medições de características específicas feitas à distância” (GIRARD, GIRARD, 1989, *apud* CASIMIRO, 2002).

Já os Sistemas de Informação Geográfica definem-se como um “conjunto de procedimentos, manual ou automatizado, utilizados no sentido de armazenamento, e manipulação de informação georreferenciada” (ARONOFF, 1989).

Deste modo, a Detecção Remota e os SIG permitem racionalizar recursos e otimizar soluções. São ferramentas essenciais no apoio à tomada de decisão, através da manipulação e tratamento de informação geográfica. Ou seja, o trabalho desenvolvido em processamento digital de imagem e análise visual de imagem, em muitas situações, pode ser o suporte necessário à criação de estratégias e respostas eficazes e sustentáveis, promovendo assim a mitigação de conflitos existentes no espaço, quer sejam fruto de processos naturais intrínsecos a este espaço, quer por acção antrópica, activa ou passiva.

O desenvolvimento das tecnologias associadas à Detecção Remota e aos Sistemas de Informação Geográfica encontram-se cada vez mais na ordem do dia. Graças a este desenvolvimento de métodos para acelerar a produção de informação geográfica, assiste-se a um crescente aumento da resolução geométrica, espectral e radiométrica das imagens, e simultaneamente, ao aparecimento de novas aplicações com o intuito de facilitar o processamento e a análise de imagens através da melhoria de algoritmos para extracção de informação. Resultado disso, são as imagens de alta resolução, provenientes do satélite *WorldView 2* e o mais recente *software Envi 5.0*, utilizados neste trabalho.

A imagem em estudo apresenta uma reflectância espectral bastante diversificada, fruto da mistura de elementos na paisagem: ora apresenta pequenas áreas de habitação de carácter informal, ora apresenta pequenas porções de

vegetação, de solo exposto, vias de comunicação pavimentadas, vias de comunicação não pavimentadas de terra batida e sombra de tudo o que tem altura.

Todas estas características aliadas à alta resolução da imagem de satélite, tornam difícil e complexa a sua classificação.

Actualmente, são várias as aplicações e os métodos disponíveis para a classificação de uma imagem. Neste estudo serão abordados dois tipos de classificação: a classificação “pixel a pixel” e a classificação orientada a objecto.

A classificação “pixel a pixel”, do tipo supervisionada, consiste na detecção de tipos específicos de cobertura do solo, conhecidos *à priori*. Requer um conhecimento preciso sobre a área de estudo para assim definir as classes de interesse e, posteriormente, aplicar o algoritmo de classificação mais adequado. Neste tipo de classificação a unidade mínima do processamento de imagem é o *pixel*.

Na classificação orientada a objecto, a unidade mínima de classificação não é o *pixel*, mas sim um conjunto de *pixels*. Inicia-se com a segmentação de imagem e procura descrever as relações entre objectos através da informação espectral e espacial, considerando não apenas as características dos *pixels*, mas também outras propriedades como a cor, a forma, a textura, a área, entre outras.

Assim sendo, e face ao anteriormente enunciado, este trabalho assenta na análise da “*performance*” do algoritmo clássico de classificação de imagem “*pixel a pixel*” e dos algoritmos de classificação de imagem por objecto, para a identificação do tipo de ocupação/uso do solo de uma imagem de alta resolução *WorldView 2* e na determinação do melhor conjunto de parâmetros para cada uma das abordagens.

## 1.2. OBJECTIVO

O presente trabalho de projecto tem como principal objectivo a análise comparada da classificação “pixel a pixel” e a classificação orientada por objecto, de uma imagem de satélite *WorldView 2*, de Maputo, referente ao ano de 2010.

Mais especificamente, pretende-se desenvolver um projecto de cartografia de uso do solo para Maputo, com recurso ao tratamento e à exploração de uma imagem de satélite de alta resolução espacial e espectral, comparando as potencialidades e limitações dos resultados extraídos através da classificação “*pixel a pixel*”, nomeadamente do classificador Máxima Verossimilhança, face às potencialidades e eventuais limitações da classificação orientada por objecto, através dos algoritmos de segmentação *K Nearest Neighbor* e *Support Vector Machine*, na extracção do mesmo número e tipo de classes de ocupação/uso do solo.

Deste modo, o presente trabalho de projecto compreende um total de três capítulos.

O primeiro capítulo trata a introdução e a contextualização da importância do presente estudo, bem como o enquadramento da área do estudo de caso, a apresentação e a descrição técnica dos dados utilizados.

No segundo capítulo, referente à metodologia, procede-se à apresentação da nomenclatura proposta de classificação e das várias fases para a concepção dos objectivos definidos. A metodologia utilizada baseia-se em duas abordagens: a abordagem baseada na classificação “*pixel a pixel*” e a abordagem baseada na classificação orientada a objecto. Assim sendo, neste capítulo, será realizada a descrição, a justificação e a análise de cada fase do trabalho, e o final do capítulo será acompanhado por um fluxograma síntese com todas as operações aplicadas ao projecto.

No terceiro capítulo, são analisados os resultados obtidos para cada tipo de classificação, com recurso à apresentação das imagens classificadas. Por forma a medir o grau de rigor e de modo a comparar o desempenho das duas abordagens na classificação de imagem, foi realizada uma análise de concordância entre os

resultados. Para tal, foram produzidos mapas e tabelas com os cálculos das respectivas classes de ocupação/uso do solo.

### 1.3. ÁREA DE ESTUDO

A imagem de satélite incide sobre Maputo, capital de Moçambique (Figura 1).

A área de estudo localiza-se no Noroeste da cidade e ocupa uma área de, aproximadamente, 0,96 km<sup>2</sup>, sendo a área total da cidade de Maputo igual a 346,77 km<sup>2</sup>. É limitada a norte pelo distrito de Marracueme, a Sul pelo Distrito de Matutuine, a Este pelo Oceano Índico e a Oeste pelo Município de Matola.

Esta imagem é caracterizada por uma grande heterogeneidade espectral, resultante da sua diversidade do uso/ocupação do solo. É constituída por edifícios, das mais variadas formas e dimensões, por vegetação do tipo herbácea e folhosa, por solo a descoberto e por algumas das principais vias de comunicação, nomeadamente, a via denominada de Avenida Julius Nyerere, que surge a Sul da imagem, a Rua Mário Coluna, que surge perpendicularmente a esta, e uma pequena parte da Avenida Maria Lurdes Mutola, situada no canto superior esquerdo da imagem.

MOÇAMBIQUE



MAPUTO



Figura 1. Localização da área de estudo

#### 1.4. DADOS

A imagem usada no trabalho de projecto, é uma imagem do satélite *WorldView 2*, obtida no dia 17 de Abril de 2010, às 8:03:26 horas.

O satélite americano *WorldView 2*, produzido pela *Digital Globe*, foi lançado a 8 de Outubro de 2009 a 770 km de altitude e, segundo as características que o representa (Quadro 1), é descrito como um dos satélites comerciais que melhor combina a muito alta resolução espacial com a muito alta resolução espectral.

**Quadro 1.** Características do Satélite *WorldView 2*

<b>Data de Lançamento</b>		8 de Outubro de 2009	
<b>Veículo de Lançamento</b>		Delta II 7920	
<b>Local de Lançamento</b>		Base da Força Aérea de Vandenberg, Califórnia, EUA	
<b>Orbita</b>	<b>Altitude</b>	770 km; 97,2° inclinação	
	<b>Tipo</b>	Heliossincrona, 10:30 am – passagem descendente	
	<b>Período</b>	100 Minutos	
	<b>Tempo de missão</b>	7,25 anos	
	<b>Frequência da passagem</b>	1,1 dias 30° <i>off nadir</i> Revisita 3,7 dias 20° <i>off nadir</i>	
<b>Ângulo de Visada</b>		+/- 45° <i>off nadir</i> = 1036 Km	
<b>Recolha de informação</b>		957 mil km por dia	
<b>Swath Width</b>		16,4 Km <i>at nadir</i>	
<b>Resolução</b>	<b>Espacial</b>	<b>Modo Pancromático</b>	50 cm
		<b>Modo Multiespectral</b>	2,0 m
	<b>Espacial</b>	<b>Modo Pancromático</b>	450 - 800 nm
		<b>Modo Multiespectral</b>	Coastal (400 - 450 μm) Blue (450 - 520 μm) Green (520 - 600 μm) Yellow (585 - 625 μm) Red (630 - 690 μm) Red Edge (705 - 745 μm) Near Infrared 1 (760 - 900 μm) Near Infrared 2 (860 - 1040 μm)
<b>Radiométrica</b>	11 bits		

Fonte: <http://www.satimagingcorp.com/satellite-sensors/worldview-2.html>

Para este estudo foram utilizadas as imagens do modo pancromático, com uma resolução espacial de 50 cm, e do modo multiespectral, com uma resolução espacial de 2 m e uma resolução espectral composta por 8 bandas. Sendo que seis destas são do espectro do visível, nomeadamente as bandas: *Coastal, Blue, Green, Yellow, Red* e *Red Edge*; e as restantes do espectro do infravermelho: as bandas do infravermelho próximo 1 e 2.

A novidade do satélite *WorldView 2* são as 4 novas bandas: *Costal*, *Yellow*, *Red edge* e *Near Infrared 2*.

Segundo a *Digital Globe*, a banda *Costal* (400 - 450  $\mu\text{m}$ ), ajuda na identificação e na análise da linha de costa e de estudos batimétricos, através da entrada da luz nas camadas de água.

A banda *Yellow* (585 - 625  $\mu\text{m}$ ) é bastante útil para detectar mudanças subtis na vegetação, no solo exposto e também na identificação de areias.

A banda *Red edge* (705 - 745  $\mu\text{m}$ ) permite observar condições relacionadas com a saúde vegetal, através do teor de clorofila. É bastante utilizada para cálculos de índices de vegetação, devido à sua posição na porção do espectro, pois encontra-se no final da absorção dos comprimentos de onda da faixa do vermelho e no início do reflexo na faixa do infravermelho.

A banda *Near Infrared 2* (860 - 1040  $\mu\text{m}$ ), tal como a banda *Near Infrared 1*, é bastante útil na análise, na identificação e composição de índices de vegetação.

Além destas características, a imagem trabalhada apresenta uma resolução radiométrica de 11 bits, o que origina uma imagem detentora de 2048 níveis digitais.

O sistema de coordenadas definido para todo o trabalho de projecto é o UTM (Zona 36S) e o Datum WGS-84.

Os dados a trabalhar serão integrados em *software Envi 5.0* e *Arcgis Desktop 10*, onde se irá desenvolver todo o processo de tratamento e exploração de dados, de modo a obter os melhores resultados possíveis.

## CAPÍTULO II. METODOLOGIA

Neste segundo capítulo serão descritos todos os procedimentos realizados ao longo do presente trabalho de projecto.

### 2.1. FUSÃO DE IMAGEM

Em primeiro lugar, de modo a melhorar a qualidade dos dados de partida, considerou-se de extrema importância a realização da fusão de imagens.

O satélite *WorldView 2* capta dois tipos de imagens: uma imagem pancromática com alta resolução espacial (50 cm), e uma imagem multiespectral com menor resolução espacial (2 m), mas com 8 bandas.

Numa fase de pré-processamento, de modo a obter uma imagem com alta resolução espacial e espectral, sem perder as suas características específicas, procedeu-se à fusão de imagens. Este método consiste na combinação da imagem de alta resolução espacial, com a imagem de menor resolução, onde resulta uma imagem colorida com elevada resolução quer espacial, quer espectral. (Figura 2)

Para a fusão, a imagem pancromática foi considerada como a imagem de referência e a multiespectral a imagem a ser corrigida. Os pontos de controlo (*GCP Ground Control Points*) foram gerados automaticamente (30 pontos de controlo), onde posteriormente foi possível reposicioná-los, caso necessário, e eliminar os pontos individuais que apresentavam um erro médio quadrático<sup>1</sup> superior ao admitido.

De seguida, iniciou-se o método de reamostragem utilizando o método convolução cúbica. Neste processo, o nível de cinzento atribuído ao *pixel* na imagem corrigida é calculado pela média dos 16 *pixels* mais próximos. O método seleccionado apresenta melhores resultados em relação aos outros disponíveis pelo *software* (Interpolação bilinear, Vizinho mais próximo), pois é mais rigoroso espacialmente quando se trabalha imagens de diferentes resoluções.

O método vizinho mais próximo é apropriado para quando não se pretende alterar a resolução espacial da imagem.

---

<sup>1</sup> O valor do erro médio quadrático (RMS) tem que ser inferior a metade do *pixel* da imagem que está a ser corrigida, ou seja, tem de ser sempre inferior a 1.

Por sua vez, o método interpolação bilinear é bastante semelhante ao método convolução cúbica, mas utiliza um método de reamostragem por vizinhança de apenas 4 pixels.

Todo o processo de fusão de imagens foi realizado em *software Envi 5.0*, através do comando *Spear Pan Sharpening*.

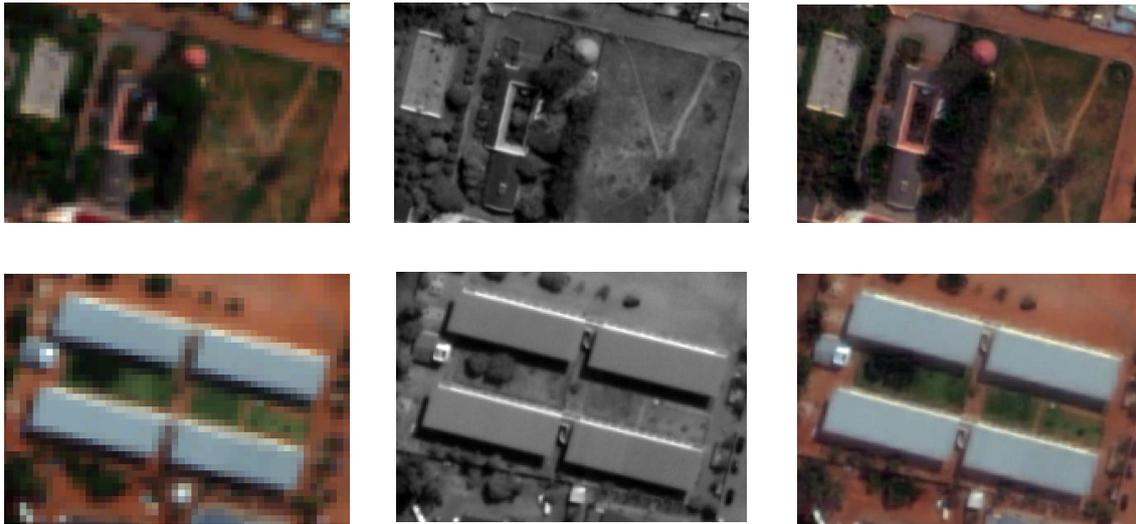


Imagem Multiespectral

Imagem Pancromática

Fusão

Fonte: PIÇARRA, J. (2014)

**Figura 2.** Fusão de Imagens *WorldView 2*

## 2.2. NOMENCLATURA PROPOSTA DE CLASSIFICAÇÃO

A nomenclatura proposta para o trabalho tem por base a realidade geográfica da área de estudo. Obedece a uma hierarquia que representa a ocupação/uso do solo em quatro níveis de detalhe e dezoito classes, partindo do mais geral para o mais específico.

No primeiro nível, a imagem divide-se em duas classes: Área Edificada e Área Não Edificada.

No segundo nível, a classe Área Edificada distribui-se em Edifícios e Vias de Comunicação. Já no terceiro nível, é tido em consideração o tipo de material de cada um dos elementos da imagem, dando origem a uma classe de edifícios com telhados de cobertura metálica/fibrocimento, e a classe das vias de comunicação, esta subdivide-se entre vias pavimentadas e vias não pavimentadas. No quarto e último nível, a separação das classes é mais específica, onde os edifícios de cobertura metálica/fibrocimento são subdivididos em cinco classes enumeradas de seguida (Figura 3):

- Edifício 1, cobertura metálica/fibrocimento, de cor cinza claro;
- Edifícios 2, cobertura metálica/fibrocimento, de cor cinza escuro;
- Edifícios 3, cobertura metálica/fibrocimento, de cor vermelha;
- Edifícios 4, cobertura metálica/fibrocimento, de cor verde;
- Edifícios 5, cobertura metálica/fibrocimento, de cor azul.

**Figura 3.** Amostra visual das classes dos edifícios, nível 4 da Nomenclatura

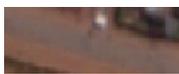
Classe Nível 4 Edifícios	Edifícios 1	Edifícios 2	Edifícios 3	Edifícios 4	Edifícios 5
Amostra Visual					
Cor	Cinza Claro	Cinza Escuro	Vermelho	Verde	Azul

As vias de comunicação pavimentadas são subdivididas em duas classes:

- Vias de comunicação pavimentadas de betão betuminoso 1, de cor cinza;
- Vias de comunicação pavimentadas de betão betuminoso 2, de cor cinza claro.

Nas vias de comunicação não pavimentadas surge apenas a classe vias de comunicação não pavimentadas de terra batida, de cor ocre. (Figura 4)

**Figura 4.** Amostra visual das classes das vias de comunicação, nível 4 da Nomenclatura

Classe Nível 4 Vias de Comunicação	Vias de Betão Betuminoso 1	Vias de Betão Betuminoso 2	Vias de Terra-batida
Amostra Visual			
Cor	Cinza	Cinza Claro	Ocre

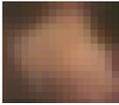
Relativamente à Área Não Edificada do primeiro nível, esta classe num segundo nível divide-se em Vegetação e Não Vegetação. Estas avançam automaticamente para quarto e último nível da Nomenclatura proposta de classificação. A classe vegetação subdivide-se em 4 novas classes enumeradas de 1 a 4, segundo o seu tom de cor vermelho. (Figura 5) Inicialmente, um dos objectivos assentava na identificação e diferenciação dos tipos de vegetação herbácea e folhosa, mas ao longo do trabalho verificou-se que tal não era exequível, pois estes dois tipos de vegetação apresentam uma resposta espectral muito semelhante.

**Figura 5.** Amostra visual das classes vegetação, nível 4 da Nomenclatura

Classe Nível 4 Vegetação	Vegetação 1	Vegetação 2	Vegetação 3	Vegetação 4
Amostra Visual				
Cor	Várias tonalidades de vermelho			

A classe Não Vegetação do segundo nível, passando automaticamente para o quarto, subdivide-se em 5 classes do tipo solo a descoberto, numeradas segundo as várias tonalidades de bege, desde a cor mais clara à cor mais escura. (Figura 6)

**Figura 6.** Amostra visual das classes solo a descoberto, nível 4 da Nomenclatura

Classe Nível 4 Solo a descoberto	Solo a descoberto 1	Solo a descoberto 2	Solo a descoberto 3	Solo a descoberto 4	Solo a descoberto 5
Amostra Visual					
Cor	Várias tonalidades de bege				

Ainda no nível 4 da Nomenclatura, ao longo da metodologia do trabalho de projecto achou-se pertinente a criação de uma última classe, a classe sombra, no sentido de diminuir os efeitos negativos que este elemento provoca na classificação de uma imagem, como exemplo concreto, a confusão espectral deste elemento com outras classes. Facto que será apresentado nas alíneas seguintes deste capítulo.

**Figura 7.** Amostra visual da classe sombra, nível 4 da Nomenclatura

Classe Nível 4 Sombra	Sombra
Amostra Visual	

### 2.2.1. ESQUEMA SÍNTESE DA NOMENCLATURA PROPOSTA DE CLASSIFICAÇÃO

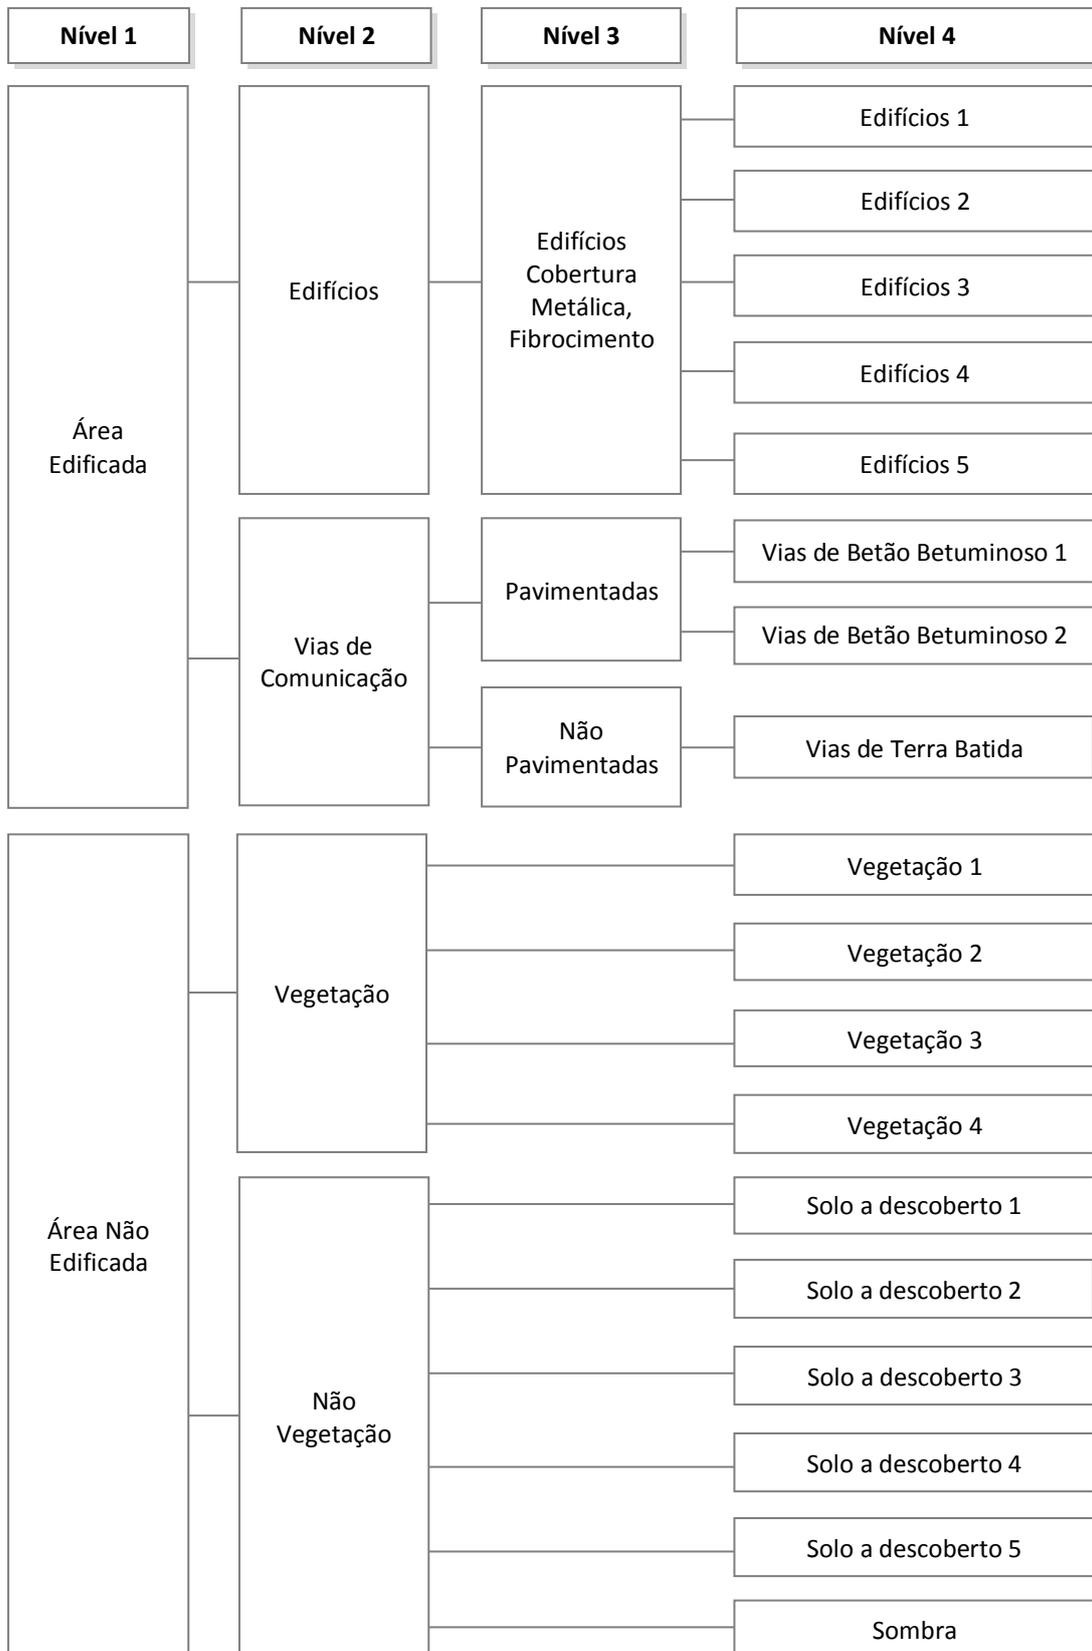


Figura 8. Nomenclatura proposta de classificação

### 2.3. CLASSIFICAÇÃO “PIXEL A PIXEL”

Existem dois tipos de classificação de imagem: a classificação supervisionada e a classificação não supervisionada.

Na classificação supervisionada o processamento de imagens é semiautomático, consiste na detecção de tipos específicos de cobertura do solo, conhecidos *à priori*, requerendo assim um conhecimento preciso sobre a área de estudo. Este conhecimento pode ser resultado de trabalho de campo e/ou da interpretação visual de imagem.

Na classificação não supervisionada o processamento digital de imagens é automático, o operador só intervém no estabelecimento do número de classes (e não no tipo de classes), no número de iterações e no estabelecimento da correspondência entre as classes espectrais obtidas e as classes desejadas.

“No método não supervisionado realiza-se a geração de aglomerados de assinaturas espectrais, no espaço multiespectral, através do estabelecimento de alguma semelhança entre eles, estabelecida por medidas de similaridade entre as assinaturas espectrais, distâncias entre os centros dos aglomerados e critérios de aglutinação, de modo a identificar-se quais as classes espectrais em que a imagem se pode segmentar” (FONSECA, FERNANDES, 2004).

Este método consiste na identificação e separação de tipos de cobertura de solo, consoante o comportamento espectral dos elementos na imagem. Trata-se de um procedimento exploratório para verificar quantas classes são estatisticamente separáveis, formando *clusters*, conforme as características espectrais dos *pixels*. No entanto, os *clusters* gerados podem ou não coincidir com as classes de interesse. Os algoritmos comuns para este tipo de classificação são o *K-means* e o *Isodata*.

Não obstante a todas estas características do tipo de classificação não supervisionada, e segundo o objectivo do presente estudo, neste trabalho só será considerada a classificação do tipo supervisionada.

Segundo EASTMAN (2009, *apud* GABRIEL, 2013), “o sucesso da classificação supervisionada resume-se à capacidade do classificador identificar, de forma fiável, as

diferentes assinaturas espectrais extraídas a partir de um determinado conjunto de bandas espectrais”.

Como referido anteriormente, na abordagem baseada na classificação “*pixel a pixel*”, do tipo supervisionada, as operações contidas são semiautomáticas, traduzindo assim um maior envolvimento por parte do operador. Estas operações são compostas, necessariamente, por quatro etapas comuns:

- A primeira etapa consiste na digitalização de parcelas-teste, que representarão uma amostra que deverá caracterizar espectralmente cada tema que o utilizador deseja extrair da imagem;

- A segunda etapa corresponde à criação de assinaturas espectrais, tendo em atenção o número de bandas espectrais e as parcelas-teste recolhidas na fase anterior;

- Na terceira etapa ocorre a comparação de assinaturas espectrais, sendo esta fase bastante pertinente, visto que objectos de natureza diferente podem apresentar a mesma assinatura espectral e, assinaturas espectrais diferentes podem associar-se a um mesmo objecto;

- Por último, a quarta etapa, corresponde à aplicação dos algoritmos de classificação.

São vários os algoritmos que podem ser utilizados, nomeadamente, o algoritmo Paralelepípedo, Mínima Distância, Distância de Mahalanobis e Máxima Versossimilhança.

O método do Paralelepípedo, um dos mais simples da classificação supervisionada, é usual para quando se pretende classificar uma imagem de reduzida variação espectral. As classes estão delimitadas por uma área em forma de paralelepípedo, onde os lados são considerados como os limites de decisão, usando unidades de desvio padrão ou valores mínimos e máximos de reflectância dentro de cada classe.

O método Mínima Distância é descrito como um classificador aplicado para classificações mais simples, pois não recorre a uma matriz de co-variância, não sendo assim tão flexível como outros classificadores - classificador Máxima Verossimilhança. Os modelos de classe são caracterizados assim pela assimetria espectral e estes podem

ser definidas com base nos dados estatísticos, através da média de cada classe em cada banda.

Relativamente à Distância de Mahalanobis, este apresenta diversas semelhanças com o método descrito anteriormente, pois usa estatísticas para cada classe. Porém, este classificador assume que a co-variância das amostras é igual, tornando-o assim mais rápido que a Mínima Distância.

Com base na pesquisa bibliográfica e no conhecimento adquirido ao longo do percurso académico, conclui-se que o classificador Máxima Verossimilhança (MV) é o mais indicado para a imagem em estudo.

### **2.3.1. ALGORITMO DE CLASSIFICAÇÃO MÁXIMA VEROSSIMILHANÇA**

O classificador rígido MV é o que apresenta melhores resultados para a classificação “*pixel a pixel*”, pois adapta-se muito bem a paisagens heterogéneas de elevada complexidade espectral. Esta classificação é executada tendo como base a função da densidade de probabilidade de pertença a um tema, possibilitando assim definir probabilidades iguais ou diferenciadas delimitadas *à priori* para cada classe.

A classificação pelo método MV “[...] usa os dados das áreas teste para estimar as médias e variâncias das classes, que são geralmente utilizadas para estimar probabilidades. [...] considerando não só os valores médios, para assignar os pixels às classes, mas também a variabilidade dos valores de brilho nessa classe. A regra de decisão da «máxima probabilidade», implementada quantitativamente para considerar classes múltiplas e várias bandas espectrais simultaneamente, constitui uma poderosa técnica de classificação. Implica cálculo intenso, tendo por isso a desvantagem de requerer mais recursos de computação que a maioria dos outros métodos” (CAMPBELL, 1996 *apud* CASIMIRO, 2002).

Segundo RICHARDS, este método parte do princípio de que a classificação errada de um *pixel* não tem mais significado do que a classificação errada de qualquer outro *pixel* na imagem.

Para iniciar a classificação “*pixel a pixel*”, e sendo a MV um classificador supervisionado, em ambiente *Envi* importou-se a imagem resultante da fusão e iniciou-

se a digitalização das parcelas teste. Esta fase do processamento é de extrema importância, pois os resultados dos classificadores são estimados através da recolha de amostras de assinaturas espectrais das áreas representativas de cada parcela teste.

Numa fase inicial, foi utilizada uma nomenclatura diferente da apresentada anteriormente: foram definidas 7 classes para os edifícios e não foi considerada a classe sombra. As classes acrescentadas são os Edifícios 1, edifícios com telhados de cobertura de fibrocimento de cor azul\cinza “brilhante” e os Edifícios 4, edifícios com telhados de cobertura cerâmica de cor laranja. (Figura 9)

**Figura 9.** Amostra visual das classes dos edifícios, nível 4 da Nomenclatura (Amostra 1)

Classe Nível 4 Edifícios	Edifícios 1	Edifícios 2	Edifícios 3	Edifícios 4	Edifícios 5	Edifícios 6	Edifícios 7
Amostra Visual							
Cor	Azul claro	Cinza Claro	Cinza Escuro	Laranja	Vermelho	Verde	Azul

Para cada classe de ocupação/uso do solo foram digitalizadas, em média, 15 parcelas teste, também denominadas de ROI “*Regions of Interest*”.

Na digitalização das ROI, foram considerados vários critérios de selecção, tais como: a cor, a forma e a textura dos elementos na imagem. Estas foram vectorizadas o mais distribuídas espacialmente, por forma a garantir separabilidade espectral e assim obter bons resultados na classificação da imagem.

Nas classes dos edifícios, das vias de comunicação e do solo a descoberto as ROI foram digitalizadas tendo por base a imagem de combinação colorida RGB 532, e nas classes da vegetação a imagem de combinação colorida falsa cor RGB 753.

Terminada a recolha das ROI, procedeu-se à etapa seguinte, a aplicação do algoritmo de classificação.

A classificação de imagem obtida com as classes definidas na amostra 1, através do algoritmo MV, (Anexos – Figura 29. Resultado intermédio da classificação “*Pixel a Pixel*” – Máxima Verossimilhança) não apresentou os resultados pretendidos, ficando aquém das expectativas idealizadas inicialmente, tendo em conta as especificidades do classificador utilizado.

Na interpretação visual de imagem observa-se muita confusão espectral entre as classes dos edifícios. Num edifício com telhado de cobertura fibrocimento/metálica de cor cinza claro, estão contidas 2 classes distintas, a classe dos edifícios 1 e dos edifícios 2. O mesmo se sucede com os edifícios 4 e 5, conforme observável na figura seguinte.

**Figura 10.** Amostra visual dos erros de classificação entre as classes dos edifícios: Amostra 1



Outro factor negativo resultante da classificação é a sombra: alguns edifícios e algumas árvores apresentam-se delimitados pela classe dos edifícios 3, de cor cinza escuro, facto que deveria ser classificado como uma outra classe que não definida inicialmente, a classe sombra.

**Figura 11.** Amostra visual dos erros de classificação entre as classes dos edifícios e outros elementos: Amostra 1



Com o aumento da resolução espacial das imagens, e devido à inclinação do sensor e ao ângulo de incidência solar na captura da imagem, a sombra passa a ser um elemento bastante presente, prejudicando a sua classificação, pois altera a resposta espectral dos objectos, escurecendo-os ou até mesmo omitindo-os.

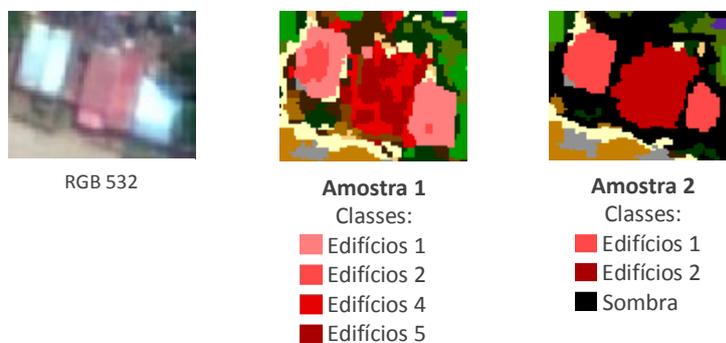
Posto isto, para melhorar a classificação resultante da amostra 1, foi formulada uma segunda amostra (Amostra 2): foi acrescentada uma última classe - classe Sombra, e as classes dos edifícios foram generalizadas - as classes dos edifícios 1 e 4 foram eliminadas, por permanecerem em minoria na imagem.

Deste modo, resultam as 18 classes definidas no nível 4 da Nomenclatura proposta, mostrada na alínea 2.2. do presente capítulo.

Face ao exposto, deu-se continuidade à classificação de imagem com a amostra 2 e, através da interpretação visual de imagem desta segunda versão, verificou-se que os resultados obtidos com recurso ao algoritmo Máxima Verossimilhança foram de encontro ao previsto inicialmente.

De um modo geral, observa-se uma boa separabilidade espectral entre as várias classes. Os edifícios extraídos já não apresentam confusão espectral entre eles e as sombras de tudo o que tem altura, foram consideradas como sombra e não como outro elemento (Figuras 12 e 13).

**Figura 12.** Amostra visual da variabilidade espectral entre as classes dos edifícios: Amostra 1 e Amostra 2



**Figura 13.** Amostra visual da variabilidade espectral entre as classes dos edifícios e Sombra: Amostra 1 e Amostra 2



Contudo, apesar de ser mínima, observa-se alguma confusão entre as classes das vias de comunicação de terra batida e as classe de solo a descoberto 3 e 4. O mesmo se sucede entre a classe das vias de comunicação de betão betuminoso do tipo 2 e os edifícios 1. Neste tipo de classificação “*pixel a pixel*” é praticamente impossível a sua diferenciação, visto que exibem uma resposta espectral muitíssimo semelhante.

Ainda em ambiente *Envi*, procedeu-se à Combinação de Classes, onde foram agrupadas as classes dos edifícios e das vias de comunicação a uma classe de área edificada e a vegetação, o solo a descoberto e sombra, agrupados à classe de área não edificada.

Esta combinação deu origem a uma imagem binária que faz a distinção entre dois tipos de solo, onde a cor vermelha está associada a área edificada e a cor cinza a área não edificada.

De seguida, os dados foram transferidos para ambiente *Arcgis Desktop 10*, para vectorização da imagem, visto que esta se encontra em formato *RASTER*, impossibilitando a sua intersecção com outro tipo de informação.

A vectorização da imagem foi possível através da ferramenta de conversão existente em *Arcgis Desktop 10*, denominada *Raster to Polygon*.

De seguida, na *shapefile* resultante da conversão para polígonos, realizou-se um *Dissolve* pelo tipo de área edificada e não edificada, para posteriormente intersectar esta informação, proveniente do classificador MV, com a informação de outros classificadores a utilizar.

Foi também elaborado um quadro associado à mesma informação da imagem, de modo a quantificar e a facilitar a sua análise.

A imagem resultante de todo este processo metodológico, bem como a sua descrição encontrar-se-á no Capítulo III, referente aos resultados.

Concluída a abordagem baseada na classificação “*pixel a pixel*”, com o algoritmo Máxima Verossimilhança, dá-se início à segunda abordagem, baseada na classificação orientada a objecto.

## 2.4. CLASSIFICAÇÃO ORIENTADA POR OBJECTO E SEGMENTAÇÃO DE IMAGEM

Para acompanhar o aumento da resolução das imagens de satélite surge uma nova abordagem na classificação de imagens, a classificação orientada a objecto, onde a unidade de mínima do processamento de imagem não é um *pixel*, mas sim um conjunto de *pixels*.

Este tipo de classificação tem como ponto de partida a segmentação, processo que constrói uma rede hierárquica de objectos e classifica-os com base nos critérios de homogeneidade, ou seja, traduz a similaridade entre objectos vizinhos, com base nos critérios de parâmetro de escala.

Através deste método, e com a utilização de diferentes algoritmos de classificação, é possível extrair automaticamente a forma dos elementos, pois é um método capaz de delimitar os objectos contidos numa imagem, agrupando os pixels com uma resposta espectral semelhante, com base na similaridade espacial, na similaridade espectral e na textura dos objectos.

Resumidamente, a segmentação de imagem procura descrever as relações entre objectos através da informação espectral e espacial, considerando não apenas as características dos *pixels*, mas também outras propriedades como a cor, a forma, a área, a textura, entre outras.

O mais recente *software* de Detecção Remota e SIG utilizado neste estudo, *Envi 5.0*, para a classificação orientada a objecto disponibiliza a ferramenta *Feature Extraction* que extrai objectos de interesse, com recurso aos atributos baseados em características espaciais, espectrais e de textura. Nesta ferramenta é possível extrair informação por meio de três comandos distintos:

1. *Segment Only Feature Extraction* – permite criar uma imagem segmentada, segundo as características dos *pixels*, com base nos critérios de parâmetro de escala, sem qualquer atribuição de regras ou de exemplos de amostras.
2. *Example Based Feature Extraction* – nesta função está incluído o comando anterior, *Segment Only Feature Extraction*, mas com a atribuição de exemplos de amostras. Consiste num processo combinado de

segmentação de imagem em objectos, e posteriormente a sua classificação por selecção de exemplos para obter as classes de interesse, segundo os atributos espaciais, espectrais e de textura definidos, e com a aplicação dos algoritmos *K Nearest Neighbor* e *Support Vector Machine*.

3. *Rule-Based Feature Extraction* – neste comando também está incluído o comando, *Segment Only Feature Extraction*, mas com a atribuição de regras. Consiste num processo combinado de segmentação de imagem em objectos, e posteriormente a sua classificação baseada em regras, para obter as classes de interesse. Contudo, este método não será desenvolvido no presente trabalho de projecto.

Para a classificação orientada a objecto, são quatro etapas metodológicas a seguir:

1. A segmentação de imagem em objectos;
2. A selecção dos exemplos de amostras, segundo as classes de interesse definidas;
3. O cálculo dos atributos espectrais, de textura e de forma;
4. A aplicação dos algoritmos de classificação *K Nearest Neighbor* e *Support Vector Machine*.

#### **2.4.1. SEGMENTAÇÃO DE IMAGEM - SEGMENT ONLY FEATURE EXTRACTION**

Para iniciar a segmentação em objectos, o *software* oferece a possibilidade de escolher entre dois algoritmos de segmentação, *Edge* e *Intensity*, e dois algoritmos de fusão, *Full Lambda Schedule* e *Fast Lambda*.

O algoritmo de segmentação *Edge*, tal como o nome indica, é um algoritmo de detecção de limites/fronteiras. É indicado para imagens mais heterogéneas, com elementos diferenciados entre si, é bastante usual para a extracção de edifícios e de vias de comunicação. Este algoritmo utiliza uma espécie de máscara que percorre a imagem à procura de descontinuidades, tendo em consideração o nível digital do *pixel*,

a forma e a textura, filtrando informação que pode ser de menor relevância, preservando, mesmo assim, as características mais importantes da imagem.

O algoritmo *Intensity* é apropriado para segmentar imagens mais homogêneas, com elementos mais subtis, sendo indicado para a extracção de bacias hidrográficas. Para este algoritmo não deve ser atribuído nenhum valor do método de fusão.

O algoritmo de fusão *Full Lambda Schedule* combina segmentos próximos com características de atributos de informação espectral, espacial e de textura semelhante. Quanto maior o valor, menor o número de segmentos gerados, proporcionando assim uma melhor precisão no contorno dos elementos

Por sua vez, o algoritmo *Fast Lambda* é menos preciso que o anterior, combinando apenas segmentos próximos com cores semelhantes.

Por último, o campo *Texture Kernel Size*, definido como o tamanho de uma janela, em *pixels*, que varia entre os valores 3 e 19, sempre em números ímpares. Para a segmentação de imagens com grandes áreas e com pouca textura, o valor deverá ser maior, próximo de 19. Caso a imagem apresente áreas mais pequenas, tais como os edifícios e árvores, o valor a utilizar no campo *Texture Kernel Size* deverá ser menor, próximo de 3.

Num exercício prático, para dar início à primeira fase da classificação orientada a objecto, a segmentação, importou-se a imagem resultante da fusão e recorreu-se à função *Segment Only Feature Extraction*, descrita inicialmente.

Segundo as características da imagem em estudo, um dos maiores desafios para este tipo de classificação é a extracção dos edifícios. Apesar da sua identificação visual ser muito simples, as suas características na imagem variam significativamente em tamanho, forma e tons (FREIRE *et al.*, 2010).

Foram vários os parâmetros testados para a segmentação de imagem em objectos: desde os algoritmos segmentação *Edge* e *Intensity*, aos algoritmos de fusão *Full Lambda Schedule* e *Fast Lambda*.

Mesmo sabendo que, à partida, o algoritmo *Intensity* não seria uma boa opção para chegar ao resultado pretendido, ainda assim o mesmo foi testado com um nível de escala de 10, 50 e 90, sem a aplicação do algoritmo de fusão e com o campo

*Texture Kernel Size* de valor 3. Como era espectável, os segmentos obtidos demonstraram-se escassos para a imagem em estudo.

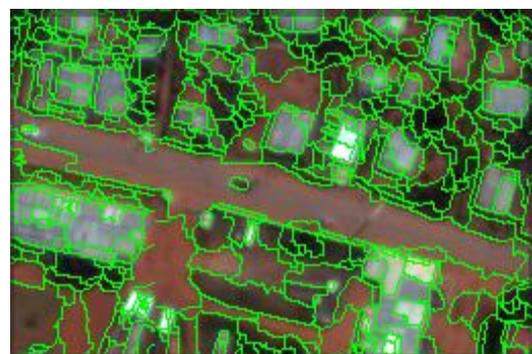
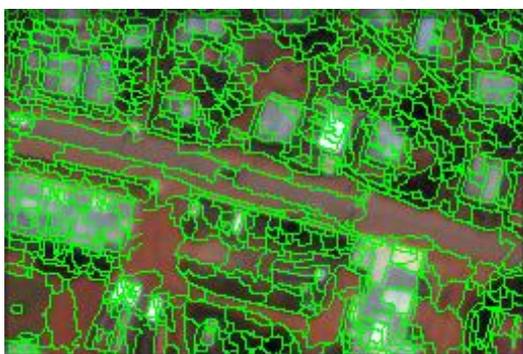
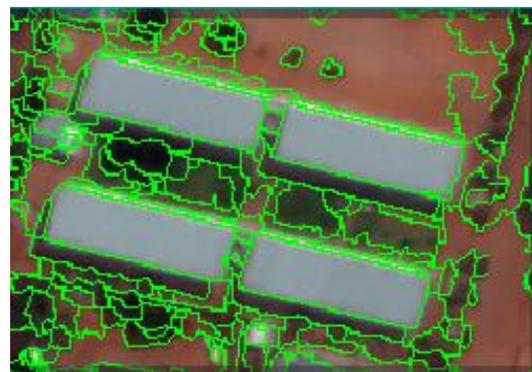
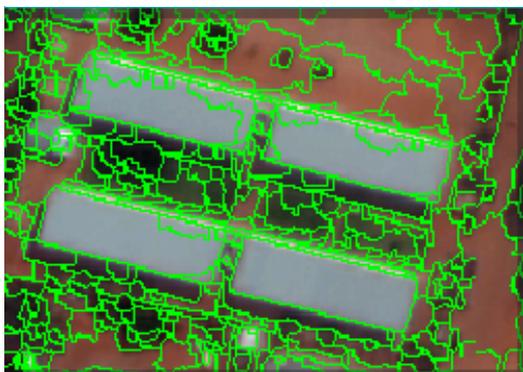
A partir desta conclusão, foram apenas explorados os algoritmos *Edge* e *Full Lambda Schedule*, fazendo variar os valores dos níveis de escala. (Anexos – Quadro 4. Tabela de Parametrização para o Modelo “*Segment Only - Feature Extraction*”)

Relativamente ao algoritmo de segmentação, os valores mais adequados para o nível de escala ficaram entre 5 e 10. Mas por fim, foi determinado o valor 5, por delimitar de forma mais precisa os elementos da imagem.

Quanto ao algoritmo de fusão, *Full Lambda Schedule*, para agregar os segmentos de menor dimensão a áreas maiores, os valores variaram entre 10, 50, 60, 70, 80 e 90, onde os melhores resultados derivaram dos valores 80 e 90.

Segundo o valor definido no nível de escala de fusão, o algoritmo de classificação anula os limites dos segmentos mais subtis, resultando uma imagem com segmentos mais generalizados.

**Figura 14.** Amostra visual dos segmentos gerados, com o algoritmo de segmentação de valor 5 e de fusão 80 e 90 - Amostra 1 e 2



Amostra 1  
Algoritmos de classificação:  
*Edge* - 5  
*Full Lambda Schedule* - 80  
8 Bandas  
Número de segmentos - 65632

Amostra 2  
Algoritmos de classificação:  
*Edge* - 5  
*Full Lambda Schedule* - 90  
8 Bandas  
Número de segmentos - 33137

Numa análise mais minuciosa sobre os segmentos gerados com um nível de fusão de valor 80, (Figura 14, Amostra 1) observa-se que estes não produzem uma divisão certa da realidade, gerando segmentos indesejados. Apesar de os parâmetros utilizados serem os que melhor diferenciam as vias de comunicação de betão betuminoso 2 dos limites de plataforma/bermas de terra batida, os restantes elementos da imagem, como os edifícios, a vegetação e o solo a descoberto surgem exageradamente repartidos.

A amostra 2 apresenta menos repartições na extracção dos edifícios, da vegetação e do solo a descoberto que a amostra 1. No entanto, em alguns segmentos, este apresenta dificuldades na diferenciação das vias de comunicação de betão betuminoso 2 com o limite de plataforma/bermas de terra batida, pois no mesmo segmento está contida a via de comunicação com o material tipo betão e a berma com o material do tipo terra batida, de cor ocre.

Após toda a fase de experimentação, análise e reflexão dos vários parâmetros exploradas para a segmentação, e segundo as características espectrais e espaciais da imagem em estudo, conclui-se que os segmentos gerados com um nível de escala de valor 5 para a segmentação e 90 para a fusão são suficientes para a selecção de exemplos sobre os segmentos gerados, segundo as diferentes classes de interesse. (Anexos - Figura 30. Resultado intermédio da classificação orientada por objecto *Feature Extraction Segment Only*)

#### **2.4.2. SEGMENTAÇÃO DE IMAGEM - EXAMPLE BASED FEATURE EXTRACTION**

Terminada a segmentação de imagem, segue-se a selecção de exemplos, que consiste na escolha das amostras representativas de cada classe de interesse, mais especificamente: 5 classes de edifícios, 3 classes de vias de comunicação, 4 classes de vegetação, 5 classes de solo a descoberto e uma classe de sombra.

Para esta etapa do trabalho recorreu-se ao segundo comando disponibilizado pelo *software – Example Based Feature Extraction* (Anexos – Quadro 5. Tabela de Parametriação para o Modelo *Example Based Feature Extraction*).

Como o objectivo principal do trabalho de projecto assenta na análise da “*performance*” dos dois tipos de classificação de imagem para a identificação do tipo de ocupação/uso do solo, tal como na classificação “*pixel a pixel*”, para a classificação orientada a objecto foram seleccionadas, em média, 15 exemplos para cada classe do nível 4 da Nomenclatura, sendo que todos os exemplos seleccionados seguem rigorosamente a mesma posição geográfica que as ROI digitalizadas na classificação ao nível do *pixel*.

A fase seguinte à selecção das amostras representativas de cada classe consiste no cálculo dos atributos espectrais, dos atributos de textura e dos atributos espaciais e/ou de forma.

#### **2.4.2.1. ATRIBUTOS ESPECTRAIS**

Os atributos espectrais estão relacionados com a radiação reflectida e/ou emitida pelos objectos, nas diversas regiões do espectro electromagnético.

O valor do atributo espectral para cada segmento em particular é calculado a partir dos dados de cada uma das bandas que compõem a imagem, onde todos os *pixels* do segmento contribuem para o cálculo do atributo. As variáveis espectrais disponíveis pelo *software* são:

*Spectral Mean* - valor médio de *pixels* que compõem a região na banda x;

*Spectral STD* - valor do desvio padrão dos *pixels* que compõem a região na banda x.

*Spectral Max* - valor máximo de *pixels* que compreende a região na banda x;

*Spectral Min* - valor mínimo de *pixels* que compreende a região na banda x.

No processo de selecção de atributos, o *software* tem disponível a função *Auto Select Attributes*. Esta ferramenta de altíssimo desempenho “lê” a imagem e, conforme a sua leitura e segundo as características específicas da imagem, atribui automaticamente os atributos espectrais, de textura e espaciais que mais se adaptam à imagem em questão.

Para a imagem *WorldView 2* de Maputo, os atributos espectrais definidos através da função *Auto Select Attributes* foram: todas as bandas do espectro para o cálculo *Spectral Mean*; as bandas 5 e 7 para o cálculo *Spectral STD*; as bandas 1, 2, 4, 5, 6, 7 e 8 para o cálculo do valor máximo e as bandas 1, 2, 3, 5, 6, 7 e 8 para o cálculo do valor mínimo.

#### **2.4.2.2. ATRIBUTOS DE TEXTURA**

A textura é uma importante propriedade no processo de classificação de imagens, pois os elementos presentes podem distinguir-se por este atributo e, quanto mais complexa esta for, mais difícil será a classificação de imagem.

“Uma medida simples de textura é a variância do nível digital numa vizinhança de um elemento da imagem. [...] A textura pode ser regular ou aleatória. No caso de objectos naturais ela é, usualmente, aleatória. A variabilidade espectral de um mesmo tema de coberto de solo aumenta com a resolução dos sensores. A maior variabilidade dos níveis radiométricos de um determinado tema de coberto, representada numa imagem de maior resolução, diminui a separabilidade estatística das classes temáticas no espaço espectral em relação à sua representação em imagens de resolução inferior, e diminui o rigor das classificações temáticas baseadas unicamente na informação espectral. Assim, a exploração da textura, em zonas de alta variabilidade dos níveis radiométricos, permite compensar este aspecto” (FONSECA, FERNANDES, 2004).

Os atributos de textura são calculados para cada uma das bandas que compõem a imagem. O seu cálculo é constituído por duas etapas:

1. A primeira fase aplica-se à janela referente *Texture Kernel Size*, pré-definida na segmentação. Os atributos são calculados para todos os *pixels* que compreendem a janela e o resultado é referenciado ao *pixel* localizado no centro do *kernel*;
2. Em seguida, os resultados dos atributos são calculados tendo por base a média dos valores dos *pixels* incluídos no *cluster*, criando um valor de atributo final.

As variáveis de textura disponíveis pelo *software* são:

*Texture Range* – conjunto de *pixels* que compõem a região dentro do *kernel* (parâmetro definido no início da segmentação, no campo *Texture Kernel Size*);

*Texture Mean* - valor médio dos *pixels* que compõem a região do *kernel*;

*Texture Variance* - variação média dos *pixels* que compõem a região do *kernel*;

*Texture Entropy* - Valor médio de entropia dos *pixels* que compõem a região do *kernel*.

As variáveis estatísticas de textura seleccionadas para a imagem em estudo através da função *Auto Select Attributes* foram: a banda 6 para o cálculo *Texture Range*; todas as bandas para o cálculo *Textura Mean*; as bandas 1, 3, 6 e 8 para o atributo *Texture Variance* e as bandas 2, 3, 6 e 8 para o atributo *Texture Entropy*.

Importa referir que as bandas seleccionadas com a função *Auto Select Attributes* são realmente as que apresentam melhores condições de separabilidade entre as classes, pois foi testado o cálculo de atributos com todas as bandas do espectro e o resultado não se apresentou tão eficaz na separação das classes de interesse.

O cálculo da textura depende do valor atribuído à janela *Texture Kernel Size* definido na primeira fase de segmentação de imagem em objectos.

Segundo o manual do *Software Envi*, o tamanho mais indicado a atribuir à janela é aquele que causa menor variabilidade espectral na textura. Se o valor é maior, a janela pode englobar mais de uma textura em simultâneo, ou seja, pode considerar *pixels* de mais de uma classe, prejudicando o resultado final. À imagem em estudo foi atribuído o valor 3.

### 2.4.2.3. ATRIBUTOS DE FORMA

Os atributos espaciais/de forma são calculados a partir do polígono que define o limite do conjunto dos *pixels*, onde a informação das bandas não é necessária. As variáveis espaciais/de forma disponíveis pelo *software* são:

*Area* – área total do polígono;

*Length* – comprimento – é a extensão longitudinal do polígono que vai de uma extremidade à outra;

*Compactness* – compacidade – medida que indica a compacidade do polígono. Um círculo é a forma mais compacta, onde o valor de compacidade é igual a  $1/\pi$  e o valor de compacidade de um quadrado é igual a  $1/2 (\text{sqrt}(\pi))$ .

O atributo *Compactness* é dado pela seguinte fórmula matemática:

$$\text{Compactness} = \text{Sqrt}(4 * \text{Area} / \pi) / \text{outer contour length}$$

*Convexity* – convexidade – este atributo mede a convexidade do polígono. O polígono pode ser convexo ou côncavo. O valor atribuído a um polígono convexo é 1, enquanto o valor atribuído para um polígono côncavo é inferior a 1.

O atributo *Convexity* é dado pela seguinte fórmula matemática:

$$\text{Convexity} = \text{length of convex hull} / \text{Length}$$

*Solidity* – solidez – forma de medida que compara a área do polígono com a área de contorno do mesmo polígono. O valor atribuído a um polígono convexo é 1, e o valor atribuído para um polígono côncavo é inferior a 1.

O atributo *solidity* é dado pela seguinte fórmula matemática:

$$\text{Solidity} = \text{Area} / \text{area of convex hull}$$

*Roundness* – circularidade – forma de medida que compara a área do polígono com o valor do diâmetro máximo do polígono elevado ao quadrado. O diâmetro

máximo é igual ao comprimento do eixo maior de uma caixa fictícia que delimita e inclui o polígono. O valor da circularidade para um círculo é 1, e o valor para um quadrado é  $4/\pi$ .

O atributo *Roundness* é dado pela seguinte fórmula matemática:

$$\text{Roundness} = 4 * (\text{Area}) / (\pi * \text{Major Length}^2)$$

*Form Factor* – factor de forma – forma de medida que compara a área do polígono com o perímetro total. O valor do factor de forma para um círculo é 1, e o valor atribuído para um quadrado é  $\pi / 4$ .

O atributo *Form Factor* é dado pela seguinte fórmula matemática:

$$\text{Form Factor} = 4 * \pi * (\text{Area}) / (\text{total perimeter})^2$$

*Elongation* – alongamento – forma de medida que indica a relação entre o eixo maior e o eixo menor de um polígono. O valor da extensão para um quadrado é 1, e o valor atribuído para um rectângulo é maior que 1.

O atributo *Elongation* é dado pela seguinte fórmula matemática:

$$\text{Elongation} = \text{Major Length} / \text{Minor Length}$$

*Rectangular Fit* – ajuste rectangular – forma de medida que indica o quão bem a forma é descrita por um rectângulo. Este atributo compara a área do polígono com o eixo do comprimento maior e o comprimento menor de uma caixa orientada que delimita e inclui o mesmo. O valor de ajuste rectangular para um rectângulo é 1, e o valor para uma forma não-rectangular é inferior a 1.

O atributo *Rectangular Fit* é dado pela seguinte fórmula matemática:

$$\text{Rectangular Fit} = \text{Area} / (\text{Major Length} * \text{Minor Length})$$

*Main Direction* – direcção principal – indica a orientação do eixo maior para cada polígono, ou seja, calcula o ângulo resultante da intersecção do eixo maior do

polígono e o eixo x. O valor de direcção principal do polígono varia entre 0° a 180°, onde a 90° está associado o Norte/Sul e a 180° Este/Oeste.

Major Length – comprimento do eixo maior do polígono. A unidade de medida é igual à resolução espacial.

Minor Length – comprimento do eixo menor do polígono. A unidade de medida é igual à resolução espacial.

*Number of Holes* – número de “furos”.

*Hole Area / Solid Area* – é a relação da área total do polígono e a área que o circunda. O atributo *Hole Area / Solid Area* é dado pela seguinte fórmula matemática:

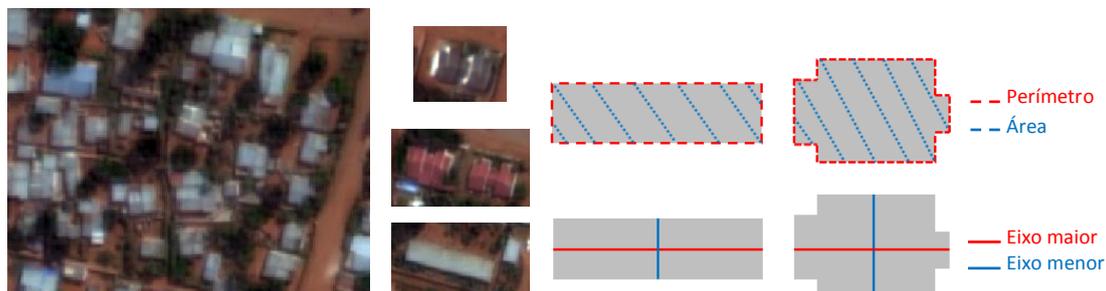
$$\text{Hole Area / Solid Area} = \text{Area / outer contour area}$$

Ao longo da metodologia foram vários os atributos de forma testados.

Face ao referido anteriormente, um dos maiores desafios para a classificação orientada a objecto é a extracção dos edifícios. Na Figura 15 é observável este mesmo facto: os edifícios que compõem a imagem apresentam as mais variadas dimensões, formas e tonalidades.

Com a função *Auto Select Attributes* os atributos de forma definidos foram os seguintes: *Convexity*, *Roundness*, *Elongation* e *Main Direction*. Contudo, após a análise dos resultados com estes atributos e tantos outros que foram aplicados em fase de experimentação, conclui-se que os mais apropriados para os diferentes elementos da imagem do estudo de caso são apenas o *Form Factor* e o *Elongation*. O atributo *Form Factor* foi seleccionado porque permite comparar a área total do polígono com o perímetro, dando assim a indicação quanto à sua forma. Por sua vez, o atributo *Elongation* possibilita o cálculo da relação entre o eixo maior e o eixo menor do polígono.

**Figura 15.** Amostra visual dos edifícios e das variáveis utilizadas para o cálculo dos atributos *Form Factor* e *Elongation*



Terminado o cálculo dos atributos espectrais, de textura e de forma, procede-se à última fase da classificação orientada a objecto, a aplicação dos algoritmos de classificação *K-Nearest Neighbor* e *Support Vector Machine*.

#### **2.4.2.4. ALGORITMO DE CLASSIFICAÇÃO *K-NEAREST NEIGHBOR***

*K-Nearest Neighbor* (KNN) é um algoritmo clássico, caracterizado pela sua facilidade de implementação, simplicidade de computação e por apresentar bons resultados na classificação de imagens.

Este método classifica os segmentos com base na proximidade das áreas de treino no espaço e quanto mais próximas estas estiverem, maior o grau de relação entre as mesmas.

O algoritmo *K-Nearest Neighbor* “classifica os objectos tendo em conta a distância a que estes se encontram das áreas de treino assumidas. Cada unidade é classificada de acordo com o maior número de ‘votos’ existentes nas unidades vizinhas” (EASTMAN, 2009, *apud* GABRIEL, 2013).

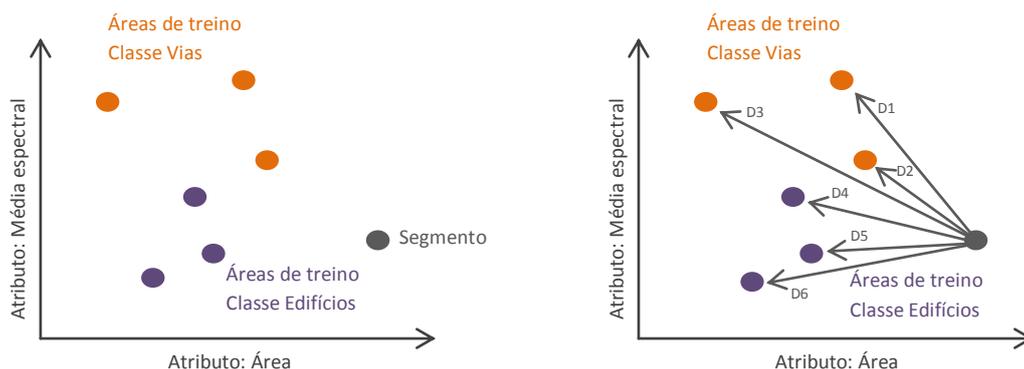
O método KNN calcula a distância euclidiana entre cada objecto da imagem segmentada e todos os objectos das amostras de exemplo, definidas *à priori*. A distância é medida em  $n$  dimensões, tanto quantos forem os atributos dos objectos das amostras, nomeadamente, os atributos espectrais, de textura e espaciais. Com este algoritmo, o *software* calcula os atributos para todas as classes definidas e estes detêm o mesmo peso na classificação.

Todavia, este método pode causar um efeito negativo no seu resultado, quando as áreas de treino não são idênticas na sua dimensão, visto que favorece as amostras de maior proporção. Outra desvantagem na aplicação do algoritmo *K Nearest Neighbor* é que o seu processamento pode tornar-se lento, especialmente quando a imagem tem milhares de segmentos. No entanto, é bastante rigoroso porque facilmente distingue as classes muito semelhantes entre si.

Como exemplo prático do funcionamento do algoritmo KNN, segue o gráfico da Figura 16 que apresenta as distâncias de um segmento para as áreas de treino.

Suponha-se que existem duas classes, edifícios e vias, e cada uma das classes é composta por 3 áreas de treino. Os atributos seleccionados para o cálculo são a área e a média espectral, para uma banda.

Figura 16. Exemplo da aplicação do algoritmo KNN



O valor *K Neighbors* tem de ser sempre um número ímpar, que pode variar entre 1 ao número igual ou inferior do total das áreas de treino. Neste caso específico, com um total de 6 áreas de treino, o valor *K Neighbors* pode ser 1, 3 ou 5.

Ao *K Neighbors* é atribuído o valor 5. Como as distâncias são calculadas de modo ascendente, fica a seguinte ordem: D2, D5, D4, D6, D, onde a distância D3 é excluída, por ser a que se encontra mais distante do segmento.

Três das distâncias do gráfico (D4, D5 e D6) são referentes à classe dos edifícios e duas das distâncias (D2 e D1) à classe das vias. Portanto, a este segmento específico é atribuída a classe dos edifícios.

Sobre a imagem em estudo, para a aplicação do algoritmo de classificação KNN, foram muitos os valores *K Neighbors* ensaiados, desde o valor 1 ao valor 99. Mas facilmente se concluiu que os valores mais baixos eram os que apresentavam uma melhor solução para a extracção das classes de interesse, pois se o valor de *K* for muito grande, a vizinhança pode incluir elementos de outras classes.

O algoritmo em análise calcula a distância entre o elemento desconhecido e os outros exemplos das classes, e a estas medidas de distância estão associados todos os atributos definidos nas fases anteriores, nomeadamente um valor de escala 5 para a segmentação, 90 para a fusão de segmentos, a selecção de 15 exemplos para cada classe do nível 4 da nomenclatura e os atributos espectrais, de textura e de forma.

Os resultados obtidos com o valor *K Neighbors* 1 e 3 são os que mais se aproximam da realidade do espaço da área em estudo.

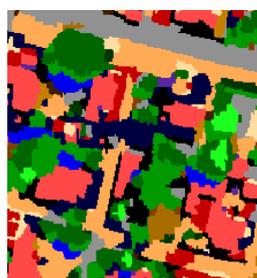
Os resultados são muito semelhantes, mas não são iguais. Com um *K Neighbors* 3, o resultado apresenta alguma confusão espectral entre as classes dos edifícios e das vias de comunicação: a classe dos edifícios 2, de telhado cor cinza escuro, surge muito nas classes das vias e também na classe associada à sombra. (Figura 17)

Parte desta confusão também sucede com um valor *K Neighbors* 1, mas em menor proporção: a classe dos edifícios 2 já não se apresentam, tão frequentemente, classificada como sombra ou como via.

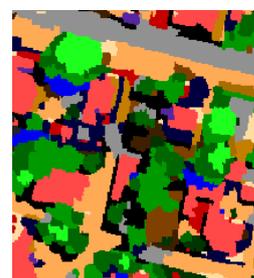
**Figura 17.** Amostra visual dos erros de classificação do algoritmo KNN, *K Neighbors* 3 e 1



RGB 753



Parâmetros utilizados:  
*K Neighbors* = 3  
Atributos espectrais e de textura:  
- bandas diferentemente distribuídas  
Atributos de forma:  
- *Elongation* e *Form Factor*



Parâmetros utilizados:  
*K Neighbors* = 1  
Atributos espectrais e de textura:  
- bandas diferentemente distribuídas  
Atributos de forma:  
- *Elongation* e *Form Factor*

Com base no acima enunciado, conclui-se que atribuindo o valor 1 para determinar o número *K Neighbors* a ser considerado pelo algoritmo, e com todos os outros atributos (espectrais, de textura e de forma), o resultado obtido é o que melhor traduz a realidade do espaço da cidade de Maputo, de elevada complexidade espectral devido aos diferentes elementos que a compõem.

#### **2.4.2.5. ALGORITMO DE CLASSIFICAÇÃO *SUPPORT VECTOR MACHINE***

O algoritmo *Support Vector Machine* é um método de classificação supervisionado bastante rigoroso, de modo que o seu tempo de processamento é mais moroso que o do algoritmo anterior.

É um método derivado da teoria da aprendizagem estatística, onde na maioria das vezes que é aplicado, produz bons resultados, mesmo que os dados de entrada sejam complexos.

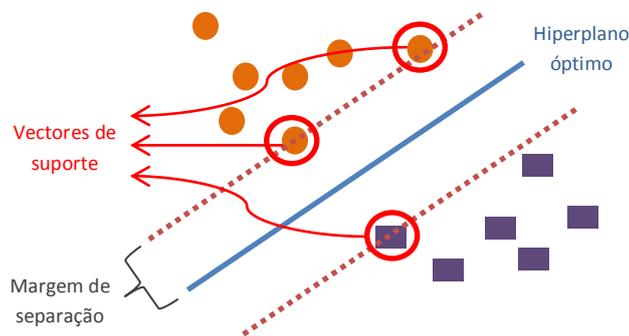
Segundo VAPNIK (1995), o algoritmo SVM tem como objectivo a determinação de limites de decisão que produzam uma separação óptima entre classes por meio da minimização dos erros.

Este método é baseado no princípio de separação óptima entre as classes: cada classe deve ter, pelo menos, duas áreas de treino, caso contrário a classe será automaticamente excluída da classificação.

A separação óptima entre as classes tem por base uma área de decisão, muitas vezes denominada de hiperplano óptimo, que consiste numa linha que separa os dados de forma otimizada. O algoritmo SVM procura o referido hiperplano óptimo, através do cálculo da mesma distância para os elementos de todas as classes, onde os seus pontos mais próximos são denominados de vectores de suporte, os elementos mais críticos do conjunto das áreas de treino.

Na figura seguinte está exemplificado um hiperplano que divide as classes, maximizando a margem de separação entre elas.

**Figura 18.** Algoritmo SVM - Hiperplano de separação óptima para duas classes



Este é um exemplo prático para apenas duas classes, onde o hiperplano óptimo, na separação das classes, funciona bastante bem. No entanto, para a imagem em estudo são vários os pontos críticos, que não serão separáveis de forma tão linear, como o exemplo anteriormente apresentado. Apesar da complexidade da área de estudo, segundo a bibliografia consultada e o manual do *software*, o modelo SVM está apto para realizar a separação óptima entre as classes, mesmo que os limites das mesmas sejam muito complexos.

O ideal seria que o algoritmo SVM calculasse um hiperplano que separasse completamente os vectores de suporte, os pontos críticos, no entanto, muitas vezes não é possível a separação perfeita. Para permitir alguma flexibilidade em separar as classes, o modelo SVM apresenta um parâmetro de nome *Penalty Parameter* (parâmetro de penalidade). Este parâmetro cria uma margem suave que permite alguns erros de classificação, que é particularmente importante para os conjuntos de áreas não separáveis.

Avançando para a informação referente à aplicação do algoritmo SVM sobre a imagem *WorldView 2* de Maputo, são vários os parâmetros a testar.

O *software Envi 5.0*, disponibiliza ao utilizador quatro tipos de funções *Kernel*: a função linear, polinomial, sigmóide e de base radial. Para o presente estudo optou-se pela função de base radial, porque segundo o manual do *software*, esta função apresenta os melhores resultados na separação óptima das classes. Nesta função é necessário atribuir um valor para *Gamma in Kernel Function* (que terá de ser superior a 0.01) e para *Penalty Parameter*. Ao valor *Gamma in Kernel Function*, o valor a atribuir

deve corresponde a  $1/n$ , onde  $n$  é o número de bandas, e 100 é o valor padrão para o campo referente ao *Penalty Parameter*.

Dito isto, com a selecção dos exemplos de cada classe terminada e com os atributos espectrais, de textura e de forma definidos, foi aplicado o algoritmo de classificação SVM com os seguintes valores: 0,1 ( $1/8$  bandas = 0.125) para a função *Gamma in Kernel Function* e 100 para o parâmetro de penalidade.

Na análise visual da imagem resultante dos parâmetros referidos anteriormente, conclui-se que a classificação não preenche as expectativas do algoritmo SVM. Conforme observável na Figura 19, os edifícios e as vias de comunicação da imagem surgem classificados como solo a descoberto.

Seguidamente, de modo a melhorar o resultado obtido, foram testados mais valores para a função *Gamma in Kernel Function*.

O melhor resultado para a extracção das classes de interesse foi obtido usando o valor 0,9 para a função *Gamma in Kernel Function* e 100 para o parâmetro de penalidade. Esta é a prova de que apesar de existirem muitos parâmetros padrão de extracção definidos para os vários tipos de classificação, estes dependem fortemente da área de estudo, das características espectrais, de textura e de forma da imagem.

**Figura 19.** Amostra visual dos erros de classificação do algoritmo SVM entre as classes dos edifícios e outros elementos



RGB 532



Parâmetros utilizados:  
*Gamma in Kernel Function* = 0,1  
*Penalty Parameter* = 100  
Atributos espectrais e de textura:  
- bandas diferentemente distribuídas  
Atributos de forma:  
- *Elongation* e *Form Factor*



Parâmetros utilizados:  
*Gamma in Kernel Function* = 0,9  
*Penalty Parameter* = 100  
Atributos espectrais e de textura:  
- bandas diferentemente distribuídas  
Atributos de forma:  
- *Elongation* e *Form Factor*

Ao longo da metodologia referente à classificação orientada por objecto, foram testados outros atributos de forma, à excepção do *Elongation*. De destacar que o atributo de forma *Elongation* é indispensável para a extracção automática das vias de

comunicação, pois da utilização deste atributo resulta um menor erro de classificação entre as classes. Sem a aplicação deste atributo de forma, as classes de solo a descoberto surgiam, muitas vezes, na classe das vias de comunicação.

Para finalizar, ainda em ambiente *Envi* procedeu-se à combinação de classes das classificações resultantes dos algoritmos KNN e SVM, onde foram agrupadas as classes dos edifícios e das vias de comunicação a uma classe de área edificada e a vegetação, o solo a descoberto e sombra a uma classe de área não edificada.

Com a classificação orientada a objecto e a combinação de classes terminada, concluíram-se os trabalhos em ambiente *Envi*. De seguida, foram exportadas as imagens para *software Arcgis Desktop 10*, para assim explorar e analisar os dados de forma quantitativa.

Em ambiente *Arcgis*, realizou-se a vectorização das imagens através da ferramenta *Raster to Polygon*.

Com as imagens vectorizadas, na *shapefile* resultante da conversão para polígonos realizou-se um *Dissolve* pelo tipo de área edificada e não edificada. Na tabela de atributos acrescentou-se uma coluna para o cálculo das respectivas áreas e, de seguida, construiu-se um quadro associado à mesma informação das imagens, de modo a quantificar e a facilitar a sua análise.

Para uma análise mais pormenorizada e de modo a calcular a área comum entre os resultados, realizou-se a intersecção dos resultados da aplicação dos algoritmos de classificação MV, KNN e SVM, através da função *Overlay Intersect*.

Para ilustrar os mapas presentes no capítulo III, referente à análise de concordância entre os resultados, recorreu-se à ferramenta *Map Algebra – Raster Calculator* e, com os ficheiros resultantes dos diferentes classificadores em formato *Raster*, efectuaram-se os seguintes cálculos: a diferença entre o classificador MV e KNN, MV e SVM e a diferença entre SVM e KNN.

Com estes ficheiros relacionados, e com os dados da análise de concordância entre os resultados, foi analisado o desempenho do algoritmo clássico de classificação de imagem “*pixel a pixel*” e dos algoritmos de classificação de imagem por objecto,

para a identificação do tipo de ocupação/uso do solo de uma imagem de alta resolução, do satélite *WorldView 2*.

## 2.5. FLUXOGRAMA

O fluxograma representado na Figura 20 mostra as etapas sequenciais do trabalho efectuado, agrupadas em dois conjuntos: as etapas da classificação “*pixel a pixel*” (à esquerda) e as etapas da classificação orientada por objecto (à direita).

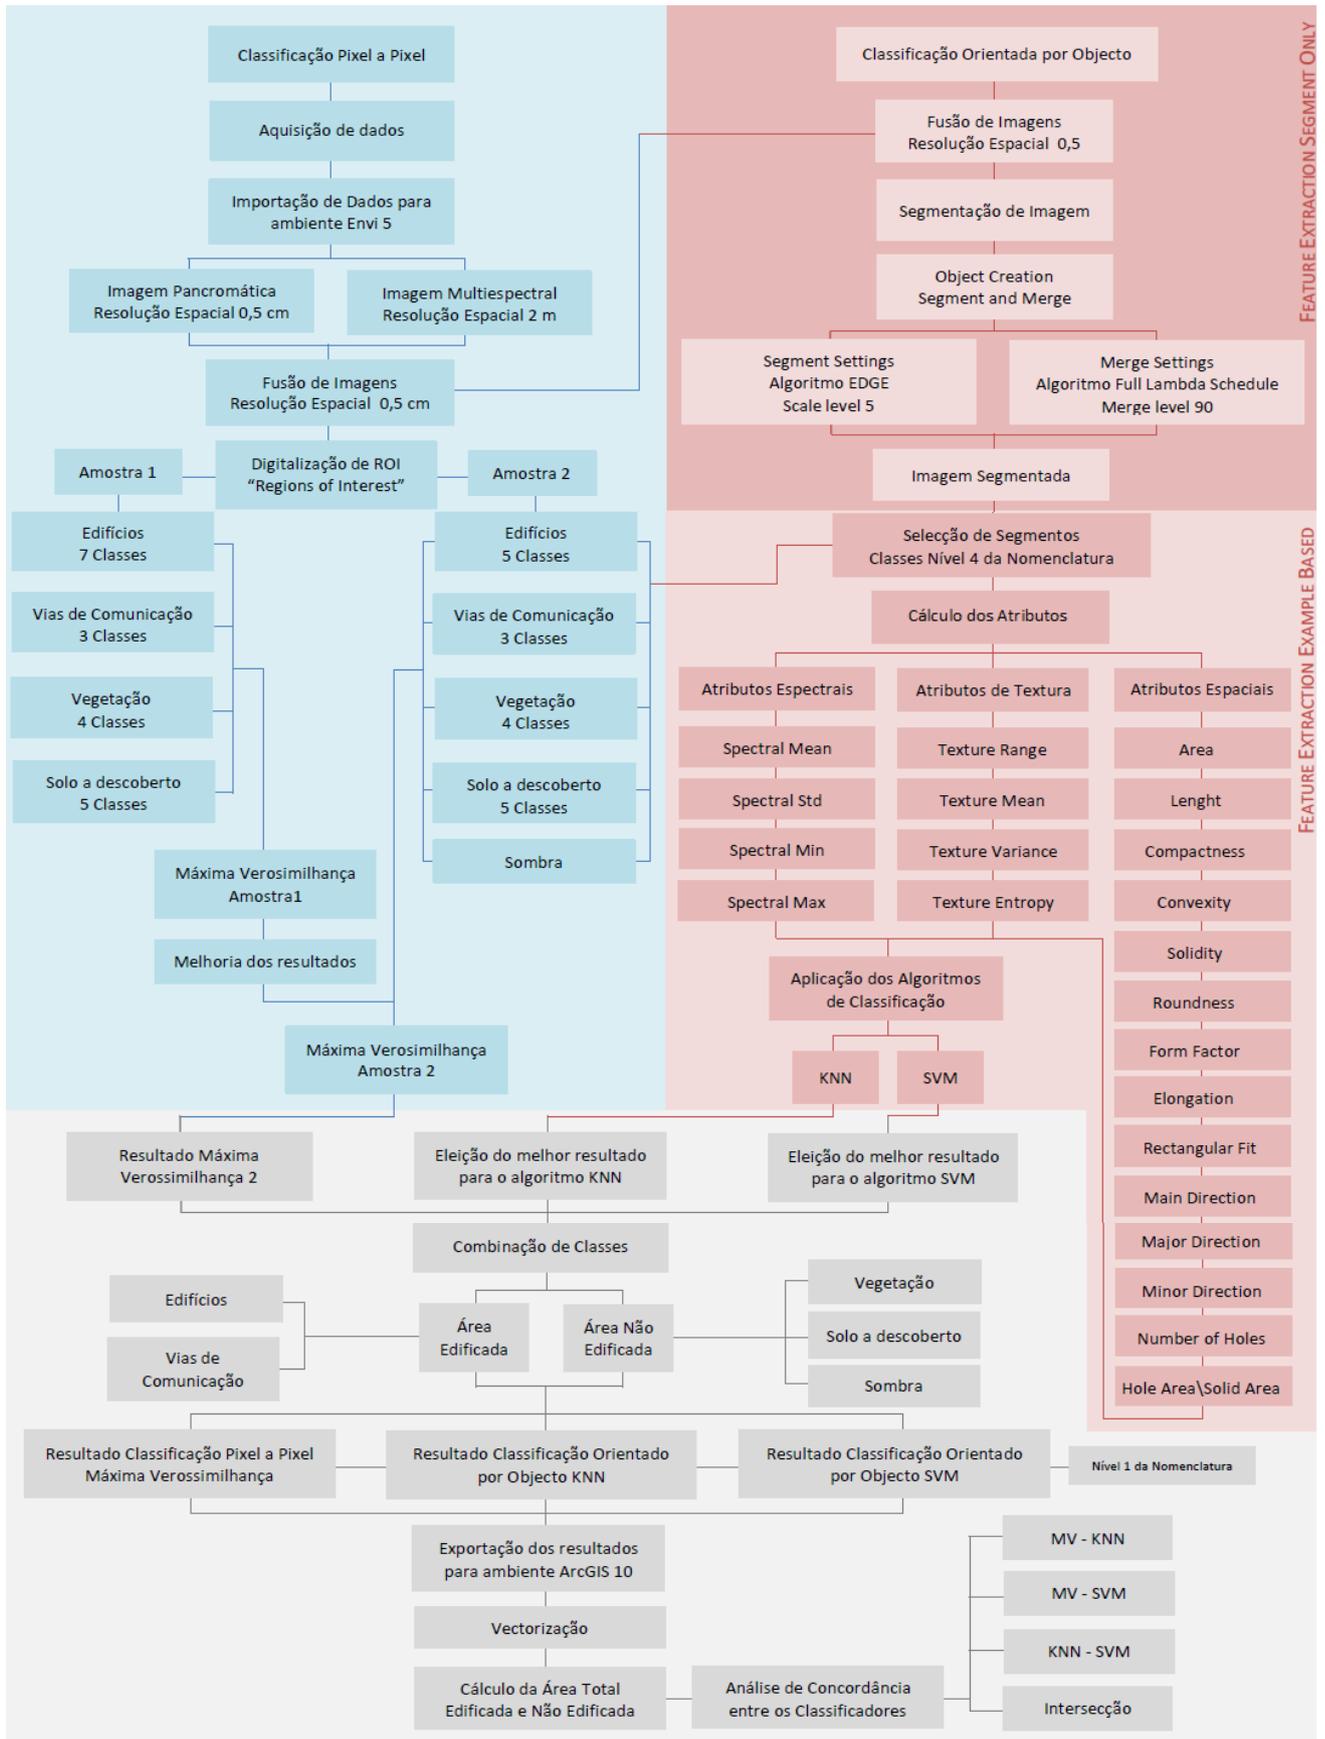
Para ambas as classificações, recorreu-se a uma imagem de alta resolução espacial e espectral, resultante da fusão das imagens pancromática e multiespectral, do satélite *WorldView 2*.

Na classificação ao nível do *pixel*, especificamente na digitalização das ROI, foi utilizada uma primeira amostra, com 20 classes de interesse e, posteriormente, de modo a melhorar os resultados, foi formulada uma segunda amostra, com 18 classes de interesse e a respectiva aplicação do algoritmo de classificação MV.

Na classificação orientada por objecto, com a imagem resultante da fusão, iniciou-se a segmentação (*Feature Extraction Segment Only*), através da função *Object Creation Segment and Merge*, onde foi atribuído o valor 5 para o algoritmo *Edge* e o valor 90 para o algoritmo *Full Lambda Schedule*. Com a imagem segmentada, procedeu-se à selecção de 15 exemplos sobre os segmentos gerados, para as 18 classes do nível 4 da Nomenclatura. De seguida, segue-se o cálculo dos atributos espectrais, de textura e de forma e a aplicação dos algoritmos de classificação KNN e SVM.

Terminada a eleição dos melhores resultados para os diferentes algoritmos, procedeu-se à combinação de classes, agrupando as classes dos edifícios e das vias de comunicação, em área edificada e, as classes da vegetação, solo a descoberto e sombra, em área não edificada. Seguidamente, as imagens foram exportadas para ambiente *Arcgis 10*, para vectorização das mesmas e, conseqüentemente para a realização dos respectivos cálculos da análise de concordância entre os resultados, nomeadamente, a diferença entre o classificador MV e KNN, MV e SVM e a diferença entre SVM e KNN.

Figura 20. Fluxograma síntese com as operações aplicadas ao projecto



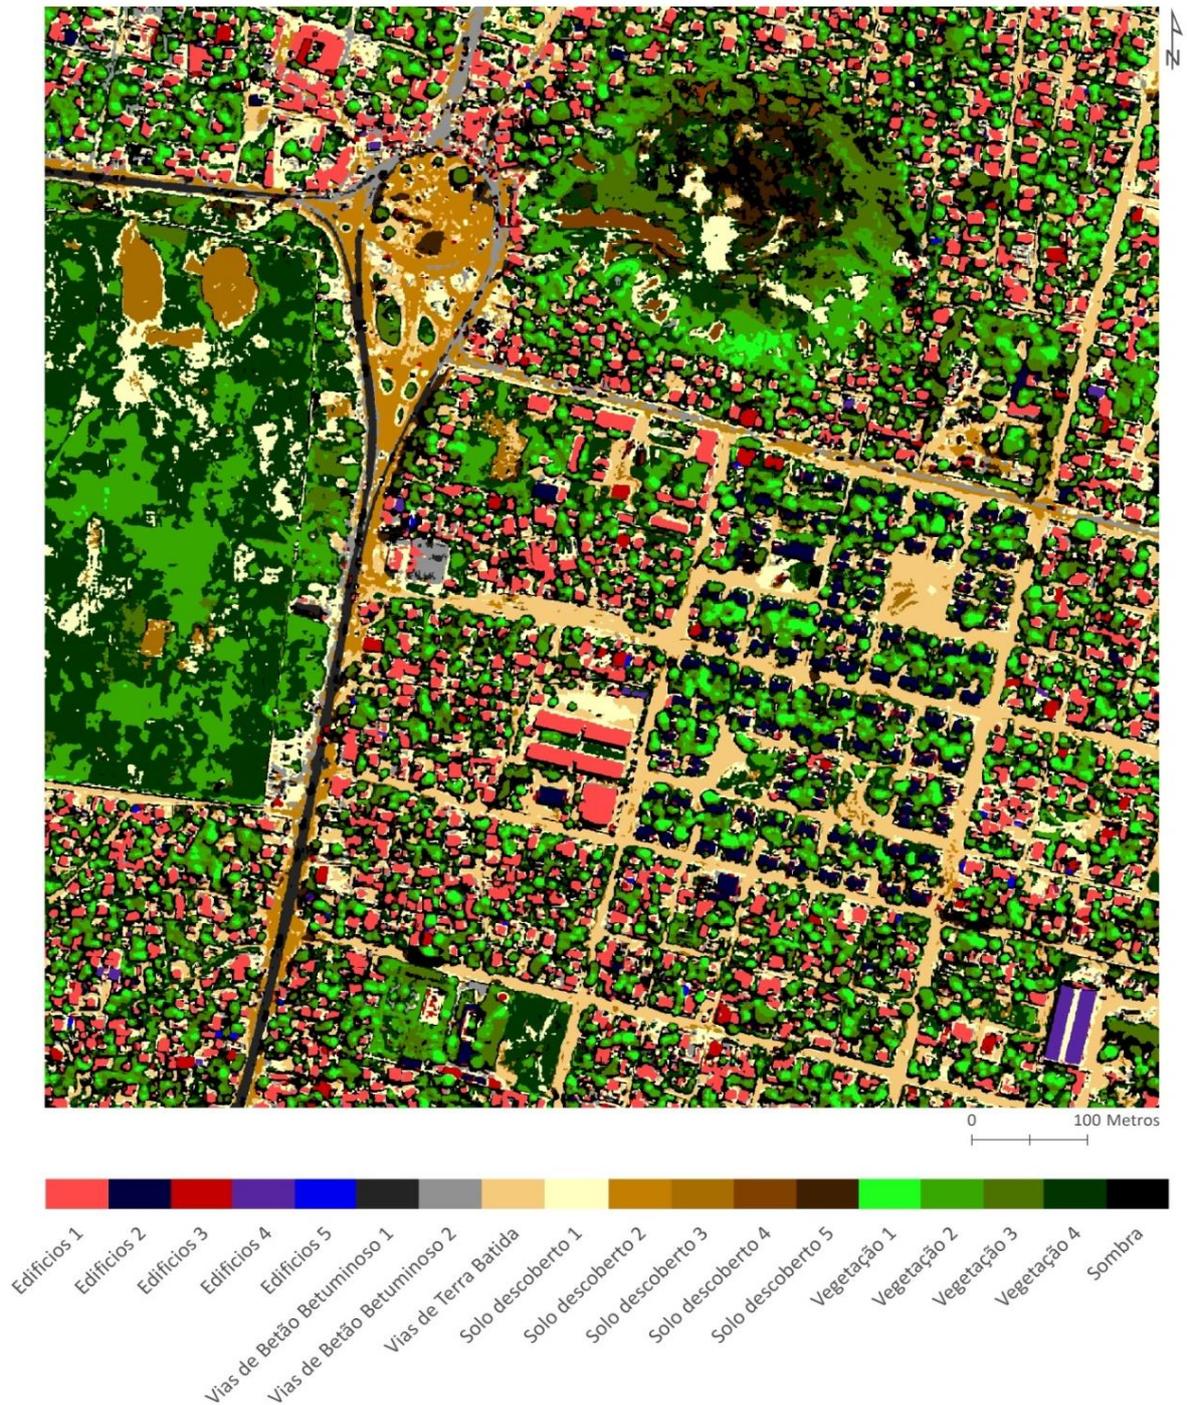
### **CAPÍTULO III. RESULTADOS**

Neste capítulo serão apresentados todos os resultados provenientes dos procedimentos metodológicos anteriormente explicitados, bem como os respectivos quadros da análise de concordância entre o resultado da classificação “*pixel a pixel*”, com o algoritmo Máxima Verossimilhança, e os resultados da classificação orientada a objecto, com os algoritmos *K Nearest Neighbor* e *Support Vector Machine*.

### 3.1. RESULTADO FINAL DA CLASSIFICAÇÃO “PIXEL A PIXEL” - MÁXIMA VEROSSIMILHANÇA

Na seguinte figura, apresenta-se o resultado final da classificação supervisionada ao nível do *pixel*, pelo algoritmo de classificação Máxima Verossimilhança.

Resultado da Classificação "Pixel a Pixel" - Máxima Verossimilhança  
Nível 4 da Nomenclatura



Fonte: PIÇARRA, J. (2014)

Figura 21. Resultado da Classificação "Pixel a Pixel" – Máxima Verossimilhança

### 3.2. RESULTADO DA CLASSIFICAÇÃO ORIENTADA POR OBJECTO - *K NEAREST NEIGHBOR*

A Figura 22 é referente ao resultado da classificação orientada por objecto, com os seguintes parâmetros: nível de escala de valor 5 para a segmentação e 90 para a fusão de segmentos; selecção de 15 exemplos sobre os segmentos para cada classe de interesse; algoritmo de classificação *K Nearest Neighbor*; bandas diferentemente distribuídas para o cálculo dos atributos espectrais e de textura; e atributos de forma *Elongation e Form Factor*.

Resultado da Classificação Orientada por Objecto - *K Nearest Neighbor*  
Nível 4 da Nomenclatura



Fonte: PIÇARRA, J. (2014)

**Figura 22.** Resultado da classificação orientada por objecto – *k Nearest Neighbor*

### 3.3. RESULTADO DA CLASSIFICAÇÃO ORIENTADA POR OBJECTO - *SUPPORT VECTOR MACHINE*

A Figura 23 apresenta o resultado da classificação orientada por objecto através dos seguintes parâmetros: nível de escala de valor 5 para a segmentação e 90 para a fusão de segmentos; selecção de 15 exemplos sobre os segmentos para cada classe de interesse; algoritmo de classificação *Support Vector Machine*; bandas diferentemente distribuídas para o cálculo dos atributos espectrais e de textura; e atributos de forma *Elongation* e *Form Factor*.

Resultado da Classificação Orientada por Objecto - *Support Vector Machine*  
Nível 4 da Nomenclatura



Fonte: PIÇARRA, J. (2014)

**Figura 23.** Resultado da classificação orientada por objecto - *Support Vector Machine*

### 3.4. ANÁLISE DE CONCORDÂNCIA ENTRE OS RESULTADOS DOS CLASSIFICADORES

Para quantificar a informação resultante dos diferentes algoritmos de classificação “*pixel a pixel*” e orientada a objecto, foram elaboradas tabelas com base nos valores das áreas resultantes da combinação de classes, ou seja, do total da área edificada e da área não edificada – Nível 1 da Nomenclatura proposta.

	Quadro 2. Área Total Edificada e Não Edificada, segundo os diferentes classificadores							
	Máxima Verossimilhança		<i>K Nearest Neighbor</i>		<i>Support Vector Machine</i>		Intersecção	
	(ha)	(%)	(ha)	(%)	(ha)	(%)	(ha)	(%)
Área Edificada	23,41	24,29	37	38,39	34,56	35,85	45,19	46,88
Área Não Edificada	72,98	75,71	59,39	61,61	61,83	64,15	51,2	53,12
Área Total	96,39	100	96,39	100	96,39	100	96,39	100

Numa primeira análise ao quadro acima apresentado, observa-se que o total de área não edificada predomina em todos os classificadores, no entanto com maior peso na classificação ao nível do *pixel*, com o algoritmo Máxima Verossimilhança, com um valor de 75,7%, seguido da classificação por segmentação com o algoritmo *Support Vector Machine*, com cerca de 64%, e por último o algoritmo *K Nearest Neighbor* com, aproximadamente, 61,6% de área não edificada.

Relativamente ao total da área edificada, é o classificador orientado a objecto com o algoritmo *K Nearest Neighbor* que apresenta os valores mais elevados, com cerca de 38%, de seguida está o algoritmo *Support Vector Machine* com 35,9%, e por último, o classificador ao nível do *pixel* com uma percentagem de 24,3 de área total edificada.

Por curiosidade foi calculada a intersecção dos resultados, ou seja, a área comum entre todos os classificadores aplicados ao projecto, donde resultou um total de 46,9% de área edificada e 53% de área não edificada. Os valores do algoritmo de classificação *K Nearest Neighbor* são os mais próximos do resultado da intersecção, seguidos dos valores do algoritmo *Support Vector Machine* e, por último, do algoritmo de classificação Máxima Verossimilhança.

Para medir o grau de rigor e comparar o desempenho das duas abordagens na classificação de imagem, segue a tabela da análise de concordância entre os resultados.

	<b>Quadro 3.</b> Análise de concordância entre os resultados dos classificadores					
	Máxima Verossimilhança - <i>K Nearest Neighbor</i>		Máxima Verossimilhança - <i>Support Vector Machine</i>		<i>K Nearest Neighbor</i> - <i>Support Vector Machine</i>	
	(ha)	(%)	(ha)	(%)	(ha)	(%)
Área Edificada	-13,59	-14,10	-11,15	-11,57	2,44	2,53
Área Não Edificada	13,59	14,10	11,15	11,57	-2,44	-2,53

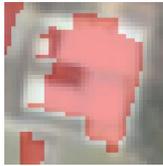
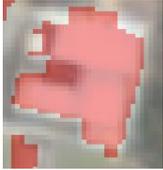
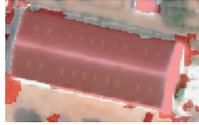
Ao observar o Quadro 3, o primeiro cálculo apresenta a diferença entre o algoritmo Máxima Verossimilhança e o algoritmo *K Nearest Neighbor*. Do cálculo efectuado resulta uma diferença de 14% para as áreas em geral, ou seja, o algoritmo ao nível do *pixel* classificou menos 14% de área edificada, do que o algoritmo orientado a objecto *K Nearest Neighbor*.

O mesmo se verifica com o algoritmo *Support Vector Machine*, mas com valores menos significativos. O algoritmo de classificação Máxima Verossimilhança revelou menos 11,6% de área edificada que o algoritmo *Support Vector Machine*.

Numa análise sobre os classificadores orientados a objecto, observa-se que a diferença entre os algoritmos *K Nearest Neighbor* e *Support Vector Machine* é mínima, de apenas 2,5%, onde o primeiro algoritmo calculou mais áreas edificadas, nomeadamente edifícios e vias de comunicação. Esta diferença mínima era espectável, visto que os atributos de segmentação, de fusão de segmentos e os atributos espectrais, de textura e de forma foram precisamente iguais, alternando somente o algoritmo de classificação.

Para uma maior percepção das diferenças dos resultados dos classificadores na extracção dos edifícios, foram recolhidas pequenas amostras dos mesmos, conforme observável na Figura 28.

**Figura 24.** Exemplos de Extacção das Classes dos Edifícios, segundo os diferentes classificadores

	Máxima Verossimilhança	<i>K Nearest Neighbor</i>	<i>Support Vector Machine</i>
			
			
			
			

O primeiro exemplo dos edifícios, a cor branca, apresenta uma forma bastante complexa, diferente do habitual. O classificador Máxima Verossimilhança foi o que se aproximou mais da configuração original deste, facto que pode ser justificado por ser um classificador ao nível do *pixel* e os outros orientados a objecto. A extracção destes últimos classificadores é bastante semelhante, no entanto para este edifício em particular o resultado do algoritmo *Support Vector Machine* é o que mais se aproxima da sua forma real, apesar de ambos generalizarem um pouco em alguns recortes do edifício.

No caso do segundo exemplo, o edifício de cor verde, é o algoritmo *K Nearest Neighbor* que apresenta a forma mais próxima à original. Como este edifício é constituído por *pixels* de mais que uma cor, o algoritmo de classificação Máxima Verossimilhança detectou-as e diferenciou-as, classificando-o erradamente: a linha que se encontra a meio do edifício foi classificada como classe de solo a descoberto 1,

por apresentar uma assinatura espectral muito semelhante a esta classe. Esta mesma linha a meio do edifício foi também detectada pelo algoritmo de classificação *Support Vector Machine*.

No terceiro exemplo, os quatro edifícios a cor cinza claro, o resultado da extracção de todos os algoritmos é razoável, visto que o edifício apresenta uma forma bastante simples. No entanto, os algoritmos orientados a objecto, apresentam uma extracção com um contorno do edifício mais preciso, ou seja, mais linear que o classificador ao nível do *pixel*.

No quarto exemplo, observa-se o resultado para a extracção de um edifício, enquadrado por pequenas vias de acesso particular e por um campo de forma rectangular de material do tipo betão betuminoso. Mais uma vez, os resultados dos classificadores *K Nearest Neighbor* e *Support Vector Machine* são bastante idênticos, apesar de o primeiro identificar uma área edificada superior: a título de exemplo surge o edifício de forma triangular posicionado no canto superior direito da imagem. O classificador Máxima Verossimilhança não reconheceu tão eficazmente as vias de acesso e o campo, considerando apenas pequenos segmentos, onde os restantes foram erradamente classificados como área não edificada.

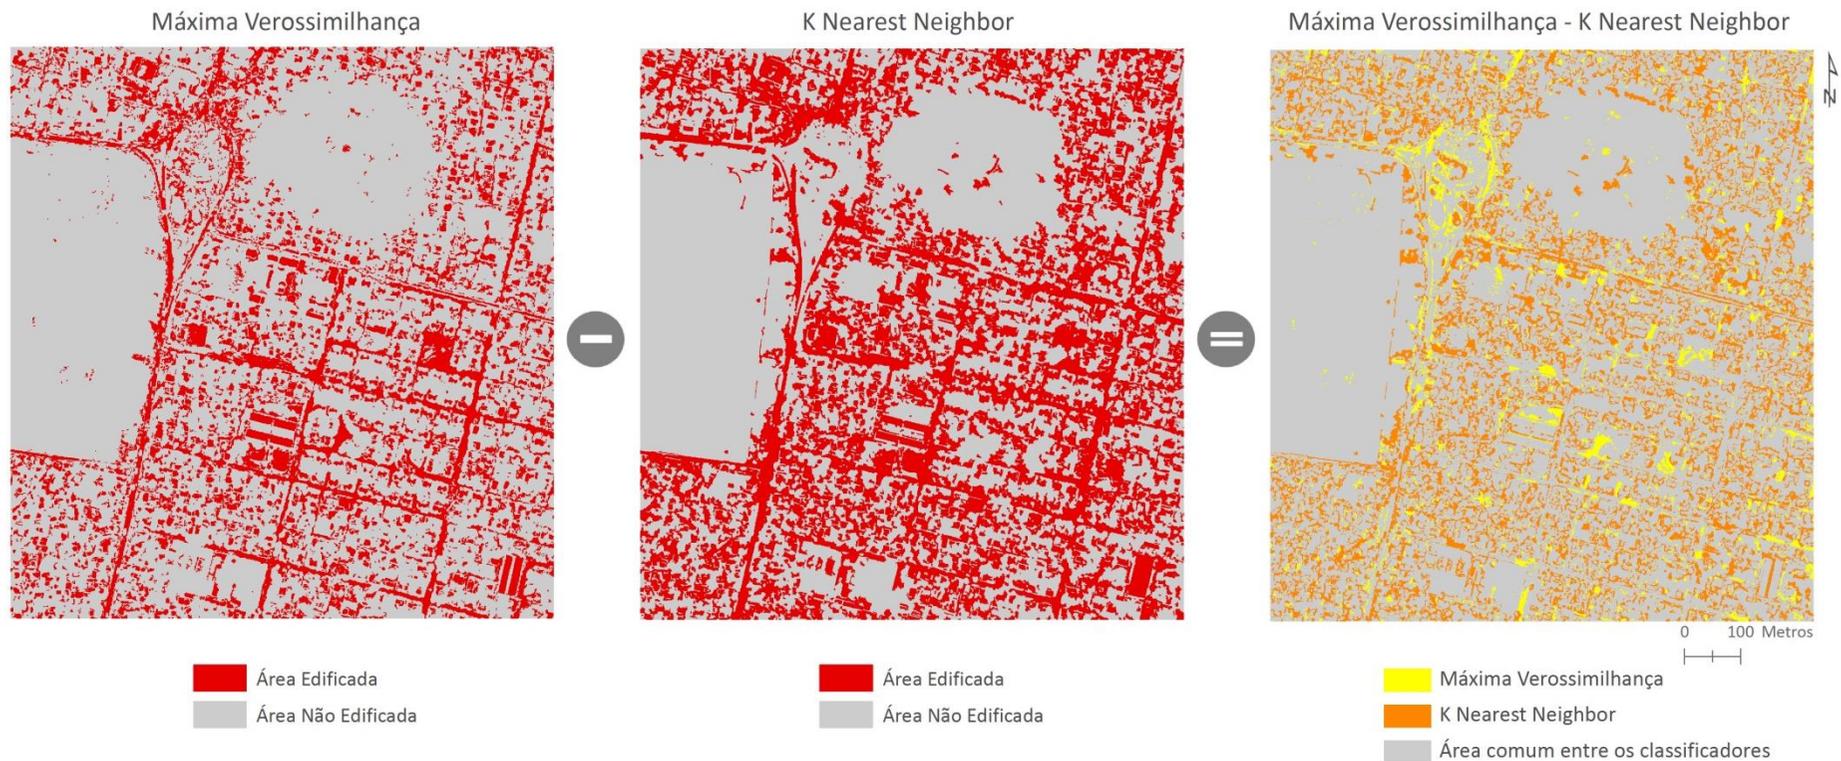
Desta análise, conclui-se que os resultados baseados na abordagem orientada a objecto são muito semelhantes, apresentando, em alguns casos, a extracção de edifícios de forma mais preenchida, resultante da generalização inerente aos classificadores. Já o algoritmo de classificação baseado na abordagem "*pixel a pixel*", nos edifícios onde que apresentava um cobertura com cores distintas, as mesmas foram diferenciadas, resultando classificações indesejadas.

Por fim, para ilustrar a informação contida nos quadros analisados, seguem os mapas com a demonstração dos cálculos efectuados na análise de concordância entre os resultados.

### 3.4.1. MÁXIMA VEROSSIMILHANÇA E K NEAREST NEIGHBOR

A Figura 24 apresenta o cálculo da diferença entre o total da área edificada, a cor vermelha, e da área não edificada, a cor cinza, do classificador Máxima Verossimilhança e do classificador *K Nearest Neighbor*. No resultado final, a cor cinza, está associada a área comum dos classificadores, a cor amarela, as áreas do classificador Máxima Verossimilhança, e a cor laranja estão representadas as áreas calculadas pelo classificador *K Nearest Neighbor*.

Resultados da Análise de Concordância entre os Classificadores



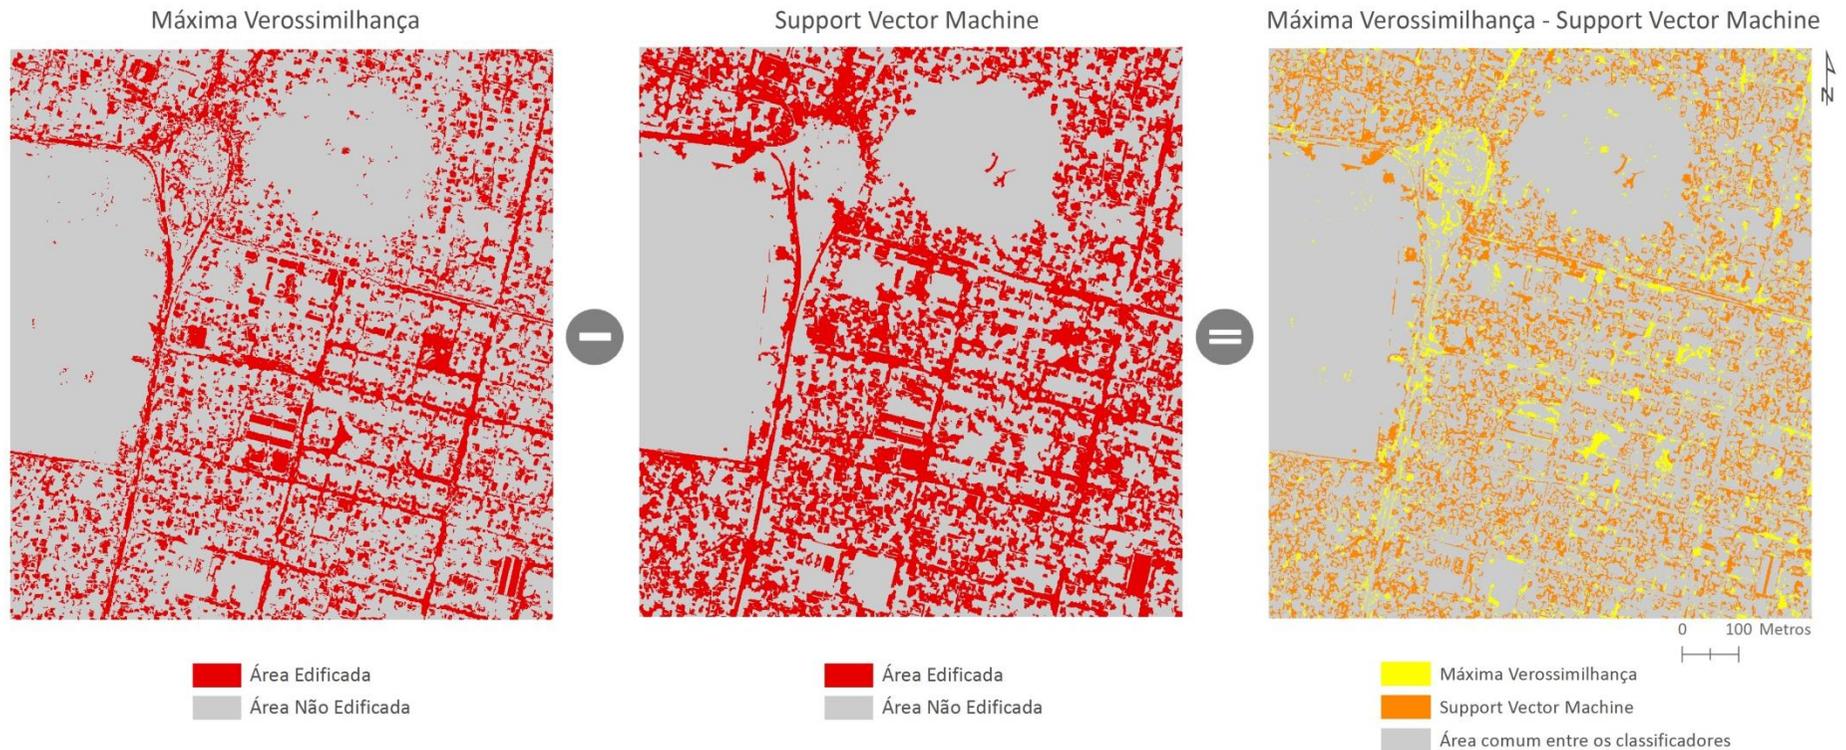
Fonte: PIÇARRA, J. (2014)

Figura 25. Análise de concordância entre os resultados: diferença entre os algoritmos Máxima Verossimilhança e *K Nearest Neighbor*

### 3.4.2. MÁXIMA VEROSSIMILHANÇA E SUPPORT VECTOR MACHINE

A Figura 25 apresenta o cálculo da diferença entre o total da área edificada e da área não edificada do classificador Máxima Verossimilhança e do classificador *Support Vector Machine*. No resultado deste cálculo, a cor cinza, está representada a área comum dos classificadores, a cor amarela, as áreas calculadas pelo algoritmo ao nível do *pixel* e, a cor laranja, as áreas calculadas pelo algoritmo *Support Vector Machine*.

Resultados da Análise de Concordância entre os Classificadores



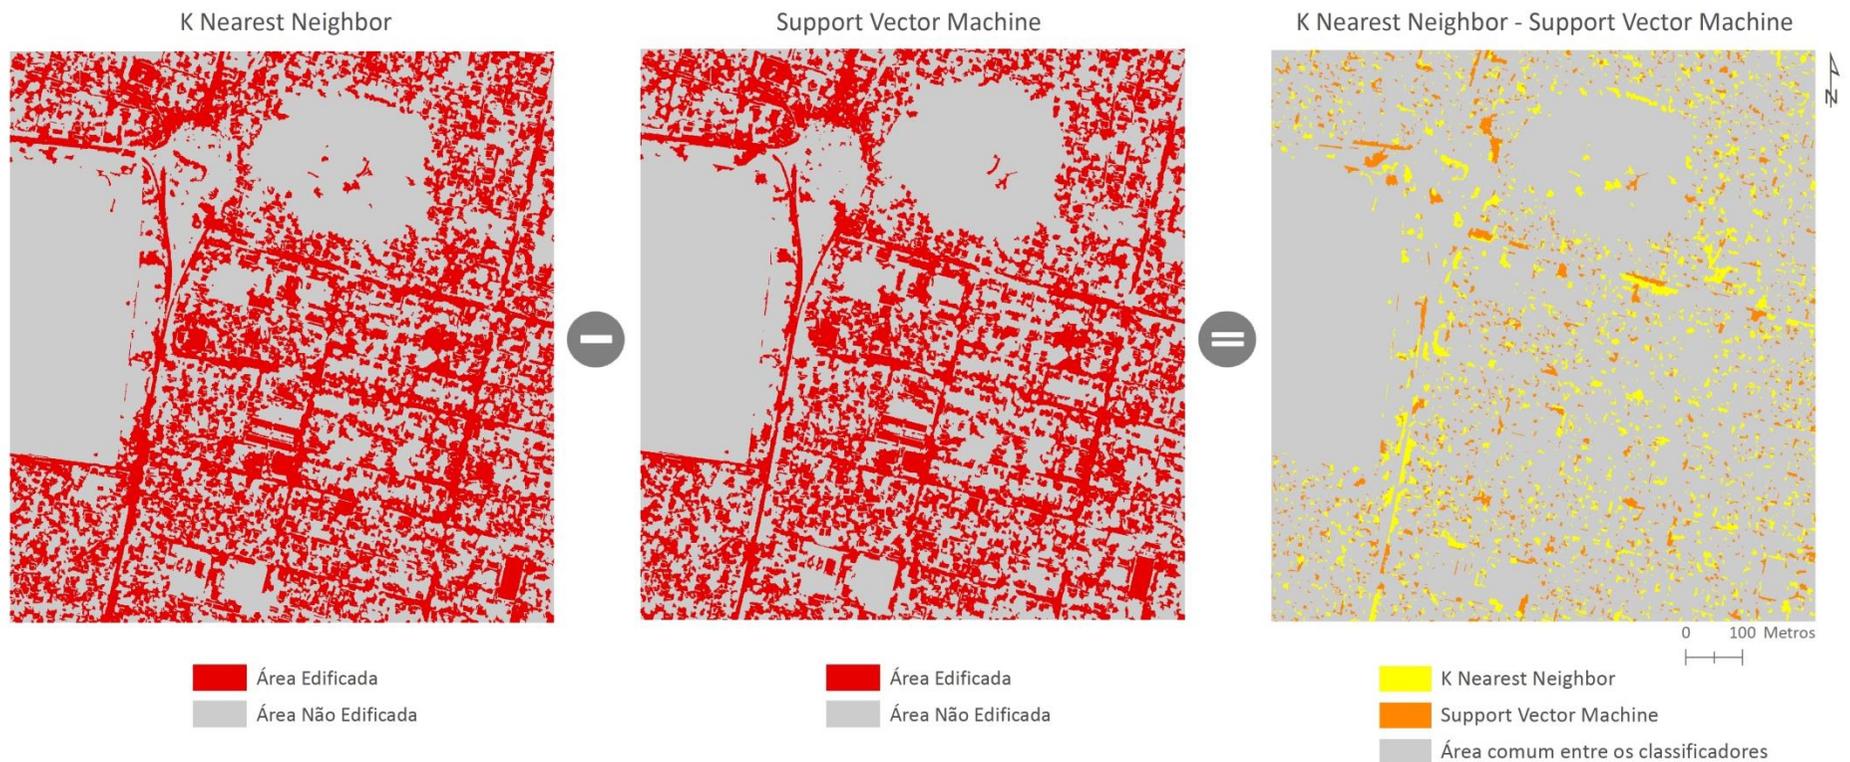
Fonte: PIÇARRA, J. (2014)

**Figura 26.** Análise de concordância entre os resultados: diferença entre os algoritmos Máxima Verossimilhança e *Support Vector Machine*

### 3.4.3. K NEAREST NEIGHBOR E SUPPORT VECTOR MACHINE

Por fim, o cálculo da diferença entre o total da área edificada e da área não edificada dos algoritmos da classificação orientada por objecto *K Nearest Neighbor* e *Support Vector Machine*. Conforme observável no quadro referente à análise de concordância, a diferença entre estes algoritmos é mínima. As áreas edificadas e não edificadas comuns entre os classificadores são evidentes, prevalecendo a cor cinza. A cor amarela, estão associadas as áreas do algoritmo *K Nearest Neighbor* e, a cor laranja, as áreas do algoritmo *Support Vector Machine*.

Resultados da Análise de Concordância entre os Classificadores



Fonte: PIÇARRA, J. (2014)

**Figura 27.** Análise de concordância entre os resultados: diferença entre os algoritmos K Nearest Neighbor e Support Vector Machine

### 3.4.4. INTERSECÇÃO DOS RESULTADOS DOS DIFERENTES CLASSIFICADORES

Na Figura 27, segue o conjunto das áreas edificadas, a cor vermelha, e das áreas não edificadas, a cor cinza, do resultado da classificação “*pixel a pixel*” com o algoritmo Máxima Verossimilhança, e dos resultados da classificação orientada por objecto, com os algoritmos *K Nearest Neighbor* e *Support Vector Machine*.

#### Intersecção dos Resultados dos Classificadores

- Máxima Verossimilhança
- K Nearest Neighbor
- Support Vector Machine



Fonte: PIÇARRA, J. (2014)

**Figura 28.** Intersecção dos resultados dos diferentes classificadores: Máxima Verossimilhança, *K Nearest Neighbor* e *Support Vector Machine*

## CONSIDERAÇÕES FINAIS

O presente trabalho de projecto, segundo o objectivo referido no Capítulo I, alínea 1.2., assenta na análise comparada da classificação “*pixel a pixel*”, através do algoritmo Máxima Verossimilhança, e na classificação orientada por objecto, com os algoritmos *K Nearest Neighbor* e *Support Vector Machine*, de uma imagem de satélite *WorldView 2*, de alta resolução espacial e espectral.

Ao longo do desenvolvimento da metodologia, foram vários os desafios, desde a vantagem da elevada resolução espacial e espectral à complexidade e heterogeneidade da área geográfica em estudo, fruto da mistura dos elementos da imagem, passando ainda pelas limitações do utilizador no conhecimento base da área em estudo e dos algoritmos utilizados na classificação orientada por objecto.

Um dos maiores desafios na classificação da imagem em estudo, encontra-se relacionado com a extracção dos edifícios: apesar da sua identificação visual ser muito simples, as suas características variam significativamente, quer em dimensão, forma e tonalidade. Outro dos desafios seria a extracção das diferentes classes das vias de comunicação, visto que a imagem em estudo era constituída por apenas três vias principais de material do tipo betão betuminoso e as restantes do material tipo terra batida, com uma resposta espectral muitíssimo semelhante às classes de solo exposto. Por último, destaca-se ainda o factor sombra na imagem, que escurece a informação existente nos *pixels*, prejudicando a sua classificação.

No que se refere à metodologia empregue no trabalho, foram utilizadas duas abordagens distintas: a primeira abordagem, baseada na classificação “*pixel a pixel*”, e a segunda abordagem, baseada na classificação orientada a objecto. Em ambas as abordagens foi considerada informação definida pelo utilizador, nomeadamente, as classes de interesse e, quanto mais áreas de treino digitalizadas (primeira abordagem) ou segmentos seleccionados (segunda abordagem) para cada classe, melhores os resultados da classificação.

Na primeira abordagem baseada na classificação “*pixel a pixel*”, com a aplicação do algoritmo de classificação Máxima Verossimilhança, foram ensaiados dois

tipos de amostra: a primeira amostra era constituída por 20 classes de ocupação/uso do solo e a segunda por 18 classes, do nível 4 da Nomenclatura proposta.

Após toda a fase de experimentação, os resultados obtidos com a primeira amostra ficaram aquém das expectativas, pois observava-se muitos erros de classificação e confusão espectral entre as várias classes. A segunda amostra, com as 18 classes de interesse foi formulada, com base nestes erros de classificação e com o objectivo de os minimizar. Nesta nova amostra, que compreendia uma nova classe, classe sombra, e omitia duas classes de edifícios, permitiu chegar a um resultado próximo das expectativas idealizadas inicialmente, onde as classes de interesse coincidem com a realidade do espaço da cidade de Maputo.

Por sua vez, na segunda abordagem, baseada na classificação orientada por objecto, recorreu-se a dois algoritmos, *K Nearest Neighbor* e *Support Vector Machine*. Em ambos os classificadores foram 4 as etapas a seguir: a segmentação de imagem em objecto; a selecção de exemplos sobre os segmentos gerados, segundo as classes de interesse definidas; o cálculo dos atributos espectrais e de textura e a aplicação do algoritmo de classificação.

Tendo por base a informação acima referida, para obter os melhores resultados foram aplicados os seguintes critérios: o valor 5 para a segmentação e 90 para a fusão de segmentos; a selecção de 15 exemplos sobre os segmentos, para as 5 classes de edifícios, 3 classes de vias de comunicação, 4 classes de vegetação, 5 classes de solo a descoberta e a classe sombra; bandas diferentemente distribuídas para o cálculo dos atributos espectrais e de textura; os atributos de forma *Elongation* e *Form Factor* e a aplicação dos algoritmos *K Nearest Neighbor* e *Support Vector Machine*.

Uma das vantagens associada a esta abordagem, baseada na classificação orientada a objecto, assenta na selecção de exemplos sobre os segmentos gerados. Esta fase foi menos morosa que na digitalização das áreas de treino na classificação ao nível do *pixel*, visto que o utilizador já detinha um conhecimento da área em estudo, conhecimento este adquirido ao longo da primeira abordagem.

Confrontando as imagens resultantes das abordagens aplicadas, verificou-se que a qualidade do mapa produzido pela classificação “*pixel a pixel*” apresenta um nível de detalhe superior aos mapas consequentes da classificação orientada por objecto. Esta diferença de nível de detalhe é justificada pela unidade de princípio do processamento de cada classificador: enquanto que na primeira abordagem a unidade mínima é o pixel, traduzindo uma maior detalhe, a segunda abordagem utiliza um conjunto de pixels, objecto, como sua unidade mínima despoletando situações de generalização.

Ainda na comparação dos resultados obtidos com a metodologia desenvolvida ao longo do trabalho de projecto, pode-se observar que, de um modo geral, a extracção da forma dos elementos e a distribuição das classes de interesse correspondem à realidade do espaço em si e, os resultados são bons face ao que é habitual em processamento semiautomático.

No entanto, os resultados finais do processamento digital de imagem, baseados na classificação orientada a objecto, podem ser aperfeiçoados, através de um estudo mais minucioso sobre os diferentes algoritmos de classificação, bem como de uma maior exploração dos parâmetros disponibilizados pelo *software*.

Em relação ao resultado associado à classificação “*pixel a pixel*”, com o algoritmo de classificação Máxima Verossimilhança, este já se encontra bastante próximo do seu nível máximo de eficácia e da representação fiel da realidade do espaço.

Apesar da “*performance*” do classificador Máxima Verossimilhança se destacar de entre os demais resultados, como referido anteriormente, não se pode afirmar que existe um classificador perfeito para a classificação de uma imagem, pois depende do objectivo inicial e das classes de interesse que se pretendem extrair, por exemplo, um classificador pode apresentar muito bons resultados na extracção dos edifícios, mas traduzir resultados menos bons na identificação de vegetação.

Face ao referido no decorrer do trabalho, pode-se depreender que a extracção semiautomática a partir de imagens é uma tarefa desafiadora, mesmo com a vantagem da riqueza espacial que estas apresentam. De destacar ainda que os

parâmetros de extração dependem fortemente da área de estudo, das suas características espectrais, de textura e de forma.

Para o desenvolvimento de projectos futuros sobre esta mesma temática, sugere-se a exploração de outros métodos para a classificação orientada a objecto, nomeadamente, o terceiro comando do *software Envi 5.0, Rule Based Feature Extraction*, que consiste num processo combinado de segmentação de imagem em objectos e que, posteriormente, realiza a sua classificação baseada em regras, para assim obter as classes de interesse. Propõe-se ainda que os vários métodos de classificação também sejam adaptados a imagens provenientes de outros satélites, com diferentes características (resolução espacial, espectral radiométrica e temporal), por forma a testar os diferentes algoritmos de classificação disponíveis e avaliar o seu desempenho nouro tipo de classes temáticas.

Da realização deste estudo, conclui-se que a par da melhoria da resolução espacial das imagens de satélite, está o aumento da variabilidade das características dos elementos contidos na imagem e, mesmo com o recurso de aplicações altamente desenvolvidas para a extração automática de objectos, é imprescindível um conhecimento base da área da estudo e da ciência Detecção Remota.

## BIBLIOGRAFIA

- BAPTISTA, H. M., 2006. Classificação hierárquica orientada a objecto em imagens de alta resolução espacial empregando atributos espaciais e de forma. Porto Alegre, Brasil. Dissertação de Mestrado.
- BLASCHKE, T., LANG, S., HAY, G., 2008. Spatial Concepts for Knowledge-Driven Remote Sensing Applications. Lecture Notes in Geoinformation and Cartography, XVII, 817 p.
- CAMPOS, A. R. et al., 2013. Classificação orientada a objeto para mapeamento do uso e cobertura do solo do município de Rio Acima - MG: por crescimento de regiões e por extração de objetos. Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil, INPE.
- CASIMIRO, P. C., 2002. Uso do solo, teledetecção e estrutura da paisagem, Ensaio Metodológico – Concelho de Mértola. Lisboa. Dissertação de Doutoramento.
- CHANG, C. C., 2001. LIBSVM: a library for support vector machines. Lin.
- CRISP, D. J., PERRY, P., REDDING, N. J., 2003. Fast Segmentation of Large Images. Intelligence, Surveillance & Technology Organisation, South Australia.
- DIGITALGLOBE, 2010. The benefits of the eight spectral bands of worldview-2. Londres.
- ESPINDOLA, G. M., 2009. Uso De algoritmos genéricos no ajuste de parâmetros da segmentação de imagens. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE, p. 6861-6868.
- FONSECA A.D., FERNANDES J.C., 2004. Detecção Remota. Lisboa: Lidel, D.L.
- FREIRE, S. et al., 2014. Introducing mapping standards in the quality assessment of buildings extracted from very high resolution satellite imagery. ISPRS Journal of Photogrammetry and Remote Sensing 90 (2014), 1–9.

- GABRIEL, C., 2013. Análise comparada de segmentação e classificação orientada por objectos de uma imagem *WorldView 2*. Lisboa. Dissertação de Mestrado.
- HARALICK, R. M., 1973. Texture features for image classification. In *IEEE Transactions on Systems, Man and Cybernetics*. vol. SMC-3, número 6.
- HENRIQUES, C. D., 2005. Monitorização da cidade africana a partir de imagens de satélite. *Cadernos da Faculdade de Arquitectura da Universidade Técnica de Lisboa*, nº 5.
- HSU, C. W., C. C. CHANG, C. J., 2010. A practical guide to support vector classification. National Taiwan University, Lin.
- JÜRGENS, C., RASHED, S., sem data. *Remote Sensing of Urban and Suburban Areas*. vol. 10.
- LOURENÇO, F. R., SANCHES, I. D., FURTADO, A. L. S., 2011. Avaliação das técnicas de fusão disponíveis nos softwares Arcgis, Erdas e ENVI. *Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, INPE*.
- MENZ, G., NUSSBAUM, S., 2008. *Object Based Image Analysis and Treaty Verification New Approaches in Remote Sensing – Applied to Nuclear Facilities in Iran*.
- NASCIMENTO, R. F. F., et al., 2009. O algoritmo Support Vector Machines (SVM): avaliação da separação ótima de classes em imagens CCD-CBERS-2. *Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal, Brasil, 25-30 abril 2009, INPE*, p. 2079-2086.
- NAVULUR, K., 2007. *Multispectral Image Analysis Using the Object Oriented Paradigm*;
- RICHARDS, J. A., 1999. *Remote Sensing Digital Image Analysis*. Springer Verlag, Berlin, p. 240.
- RODRIGUES, A. S., 2008. Metodologia de avaliação de fusão de imagens baseada em imagens sintéticas. Porto. Dissertação de Mestrado.

SANTOS, E. M., 2002. Teoria e Aplicação de Support Vector Machine à Aprendizagem e Reconhecimento de Objetos Baseado na Aparência. Campina Grande, Paraíba, Brasil. Dissertação de Mestrado.

SEMOLINI, R., 2002. Support Vector Machines, Inferência Transdutiva e o Problema de Classificação. Campina Grande, Paraíba, Brasil. Dissertação de Mestrado.

### **Portais de Internet**

<http://www.processamentodigital.com.br> (sem data).

<http://www.processamentodigital.com.br/2010/09/07/envi-fusao-de-imagens/>  
Consultado a 20 de Março de 2012.

<http://www.gadm.org> (sem data).

<http://www.gadm.org/download> Consultado a 29 de Janeiro de 2014.

<http://www.satimagingcorp.com> (sem data).

<http://www.satimagingcorp.com/satellite-sensors/worldview-2.html> Consultado a 30 de Janeiro de 2014.

<http://www.cmmaputo.gov.mz/> (sem data)

<http://www.cmmaputo.gov.mz/CMMBalcao/Default.aspx?PagId=164> Consultado a 31 de Janeiro de 2014.

<http://www.dtreg.com> (sem data).

<http://www.dtreg.com/svm.htm> Consultado a 20 de Fevereiro de 2014.

<http://www.empix.com> (sem data).

[http://www.empix.com/NE%20HELP/functions/glossary/morphometric\\_param.htm](http://www.empix.com/NE%20HELP/functions/glossary/morphometric_param.htm)  
Consultado a 27 de Fevereiro de 2014.

**Outras fontes:** Manual do *Software Envi 50.*, 2012 *Exelis Visual Information, Inc.*

## ÍNDICE DE FIGURAS

<b>Figura 1.</b> Localização da área de estudo .....	5
<b>Figura 2.</b> Fusão de Imagens <i>WorldView 2</i> .....	9
<b>Figura 3.</b> Amostra visual das classes dos edifícios, nível 4 da Nomenclatura .....	10
<b>Figura 4.</b> Amostra visual das classes das vias de comunicação, nível 4 da Nomenclatura .....	11
<b>Figura 5.</b> Amostra visual das classes vegetação, nível 4 da Nomenclatura .....	11
<b>Figura 6.</b> Amostra visual das classes solo a descoberto, nível 4 da Nomenclatura .....	12
<b>Figura 7.</b> Amostra visual da classe sombra, nível 4 da Nomenclatura.....	12
<b>Figura 8.</b> Nomenclatura proposta de classificação .....	13
<b>Figura 9.</b> Amostra visual das classes dos edifícios, nível 4 da Nomenclatura (Amostra 1) .....	17
<b>Figura 10.</b> Amostra visual dos erros de classificação entre as classes dos edifícios: Amostra 1.	18
<b>Figura 11.</b> Amostra visual dos erros de classificação entre as classes dos edifícios e outros elementos: Amostra 1.....	18
<b>Figura 12.</b> Amostra visual da variabilidade espectral entre as classes dos edifícios: Amostra 1 e Amostra 2 .....	19
<b>Figura 13.</b> Amostra visual da variabilidade espectral entre as classes dos edifícios e Sombra: Amostra 1 e Amostra 2 .....	19
<b>Figura 14.</b> Amostra visual dos segmentos gerados, com o algoritmo de segmentação de valor 5 e de fusão 80 e 90 - Amostra 1 e 2.....	24
<b>Figura 15.</b> Amostra visual dos edifícios e das variáveis utilizadas para o cálculo dos atributos <i>Form Factor</i> e <i>Elongation</i> .....	32
<b>Figura 16.</b> Exemplo da aplicação do algoritmo KNN.....	33
<b>Figura 17.</b> Amostra visual dos erros de classificação do algoritmo KNN, k Neighbors 3 e 1 .....	34
<b>Figura 18.</b> Algoritmo SVM - Hiperplano de separação óptima para duas classes .....	36
<b>Figura 19.</b> Amostra visual dos erros de classificação do algoritmo SVM entre as classes dos edifícios e outros elementos .....	37
<b>Figura 20.</b> Fluxograma síntese com as operações aplicadas ao projecto .....	40
<b>Figura 21.</b> Resultado da Classificação " <i>Pixel a Pixel</i> " – Máxima Verossimilhança.....	42
<b>Figura 22.</b> Resultado da classificação orientada por objecto – <i>k Nearest Neighbor</i> .....	43
<b>Figura 23.</b> Resultado da classificação orientada por objecto - <i>Support Vector Machine</i> .....	44
<b>Figura 24.</b> Análise de concordância entre os resultados: diferença entre os algoritmos Máxima Verossimilhança e <i>K Nearest Neighbor</i> .....	49

<b>Figura 25.</b> Análise de concordância entre os resultados: diferença entre os algoritmos Máxima Verossimilhança e <i>Support Vector Machine</i> .....	50
<b>Figura 26.</b> Análise de concordância entre os resultados: diferença entre os algoritmos <i>K Nearest Neighbor</i> e <i>Support Vector Machine</i> .....	51
<b>Figura 27.</b> Intersecção dos resultados dos diferentes classificadores: Máxima Verossimilhança, <i>K Nearest Neighbor</i> e <i>Support Vector Machine</i> .....	52
<b>Figura 28.</b> Exemplos de Extacção das Classes dos Edifícios, segundo os diferentes classificadores.....	47
<b>Figura 29.</b> Resultado intermédio da classificação “ <i>Pixel a Pixel</i> ” com a Amostra 1 .....	62
<b>Figura 30.</b> Resultado intermédio da classificação orientada por objecto.....	63

## ÍNDICE DE QUADROS

<b>Quadro 1.</b> Características do Satélite <i>WorldView 2</i> .....	6
<b>Quadro 2.</b> Área Total Edificada e Não Edificada, segundo os diferentes classificadores .....	45
<b>Quadro 3.</b> Análise de concordância entre os resultados dos classificadores .....	46
<b>Quadro 4.</b> Tabela de Parametização para o Modelo <i>Segment Only - Feature Extraction</i> .....	64
<b>Quadro 5.</b> Tabela de Parametização para o Modelo <i>Example Based - Feature Extraction</i> .....	66

## ANEXOS

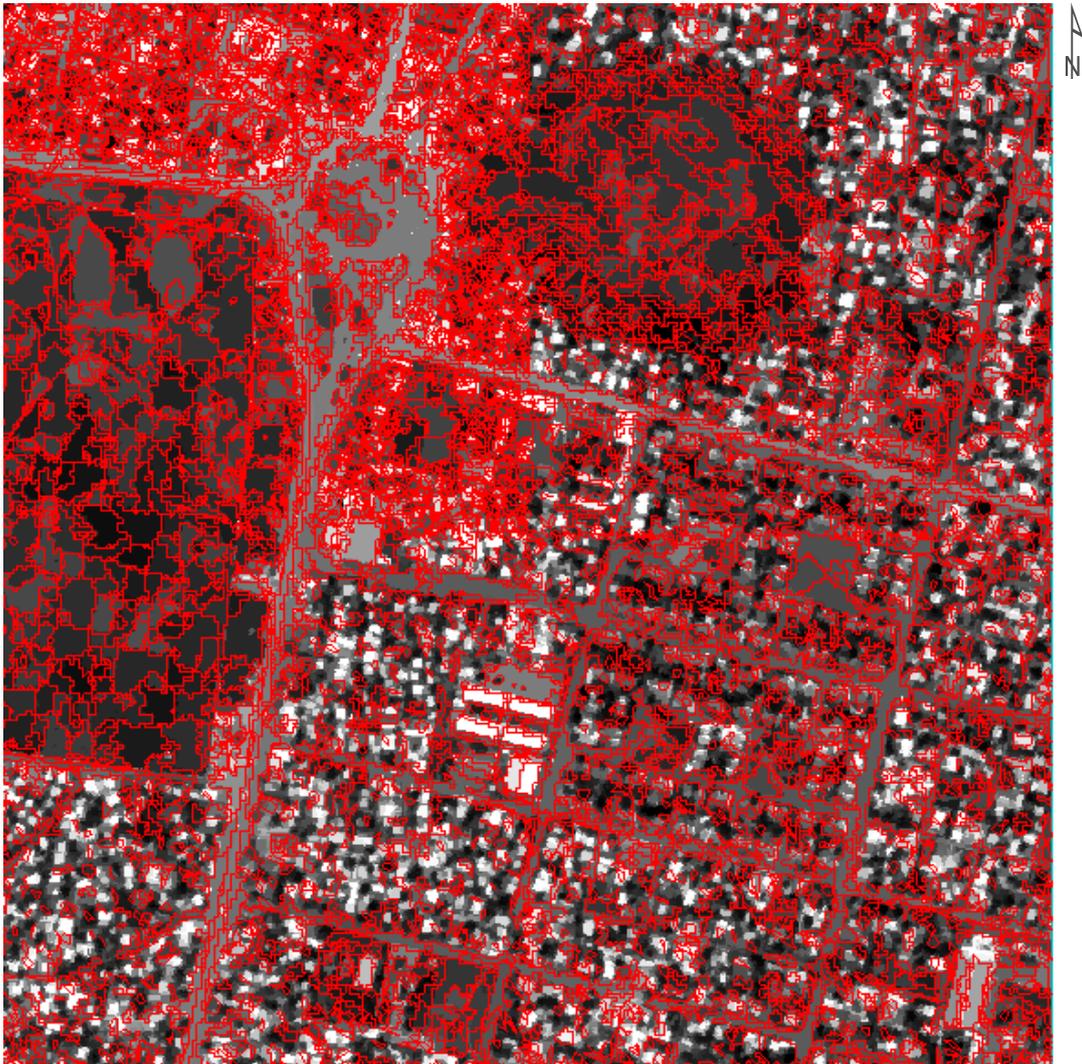
Classificação "Pixel a Pixel" - Máxima Verossimilhança  
Resultado Intermédio | Nível 4 da Nomenclatura (Amostra 1)



Fonte: PIÇARRA, J. (2014)

Figura 29. Resultado intermédio da classificação "Pixel a Pixel" com a Amostra 1

Classificação orientada por objeto - Resultado Intermédio  
*Feature Extraction Segment Only*



Algoritmos de classificação utilizados:

*Edge* - 5

*Full Lambda Schedule* - 90

8 Bandas igualmente distribuídas

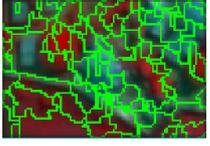
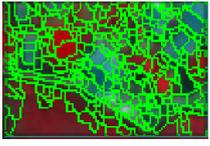
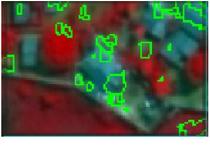
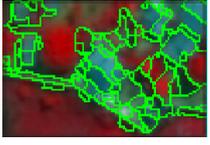
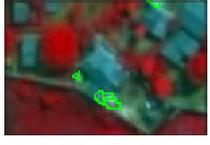
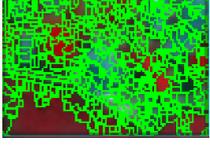
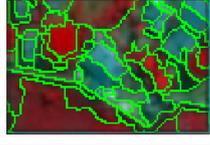
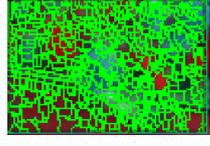
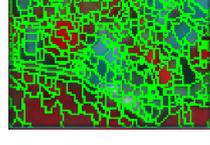
Número de segmentos - 33137

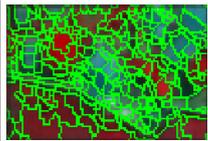
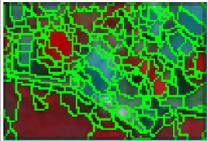
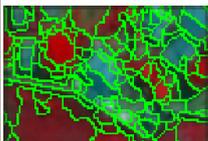
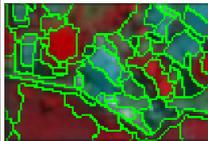
0 100 Metros  
|-----|

Fonte: PIÇARRA, J. (2014)

**Figura 30.** Resultado intermédio da classificação orientada por objecto  
*Feature Extraction Segment Only*

**Quadro 4.** Tabela de Parametrização para o Modelo *Segment Only - Feature Extraction*

	Segment Settings			Merge Settings		Texture Kernel Size (3-19)	Amostra Visual	
	Algorithm (Scale Level 0-100)		Select Segment Bands	Algorithm (Merge Level 0-100)				Select Merge Bands
	Edge	Intensity		Full Lambda Schedule	Fast Lambda			
Amostra 1		10	Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	0		3		
Amostra 2	10		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	50		3		
Amostra 3		50	Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	0		3		
Amostra 4	50		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	50		3		
Amostra 5		90	Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	0		3		
Amostra 6	90		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	50		3		
Amostra 7	10		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	10		3		
Amostra 8	10		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	90		3		
Amostra 9	5		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	10		3		
Amostra 10	5		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	50		3		

Amostra 11	5		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	60		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	3	
Amostra 12	5		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	70		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	3	
Amostra 13	5		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	80		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	3	
Amostra 14	5		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	90		Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	3	

**Quadro 5.** Tabela de Parametrização para o Modelo *Example Based - Feature Extraction*

Tentativa	Nome Ficheiro	Object Creation - Segment and Merge					Attributes Selection								Algorithms				Allow Unclassified (0-99)		
		Segment Settings		Merge Settings		Texture Kernel Size (3-19)	Spectral				Texture				Spatial	Auto Select Attributes	K Nearest Neighbor	K (1-99)		Support Vector Machine	
		Algorithm (Scale Level 0-100)	Select Segment Bands	Algorithm (Merge Level 0-100)	Select Segment Bands		Mean	Std	Min	Max	Range	Mean	Variance	Entropy						Gamma in Kernel Function	Penalty Parameter
Tentativa 1	Segment_KNN_Standard	5	Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	90	Band1, Band2, Band3, Band4, Band5, Band6, Band7, Band8	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6, 8	Band 1, 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓	✓	1			5
Tentativa 2	Segment_KNN_5	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6, 8	Band 1, 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓	✓	5			No
Tentativa 3	Segment_KNN_5_v2	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 1, 2, 3, 5, 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6	Band 3, 6	Area, Rectangular Fit; Main Direction	✓	✓	5			No
Tentativa 4	Segment_KNN_5_v3	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	All		✓		5			No
Tentativa 5	Segment_KNN_49	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6, 8	Band 1, 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓	✓	49			No
Tentativa 6	Segment_KNN_1	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6, 8	Band 1, 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓	✓	1			No
Tentativa 7	Segment_KNN_3	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓	✓	3			No
Tentativa 8	Segment_KNN_9	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓	✓	9			No
Tentativa 9	Segment_KNN_99	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓	✓	99			No

Tentativa 10	Segment_SVM_Standard	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓			0,03	100	No
Tentativa 11	Segment_SVM_Standard_v2	5	""	80	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 8	Band 2, 3, 6, 8	Length, Convexity, Solidity, Roundness, Fom Factor, Elongation, Rectangular Fit, Main Direction, Minor Length	✓			0,03	50	No
Tentativa 12	Segment_SVM_10	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓			0,03	10	No
Tentativa 13	Segment_SVM_0,1_100	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓			0,1	100	No
Tentativa 14	Segment_KNN_3_v1	5	""	90	""	9	Band 1, 2, 3, 4, 5, 6, 7, 8	0	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Convexity, Roundness, Main Direction	✓	✓	3			No
Tentativa 15	Segment_SVM_0,9_100	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓			0,9	100	No
Tentativa 16	Segment_KNN_3_ALL	5	""	90	""	3	All	All	All	All	All	All	All	All	All		✓	3			No
Tentativa 17	Segment_SVM_0,1_100_ALL	5	""	90	""	3	All	All	All	All	All	All	All	All	All				0,1	100	No
Tentativa 18	Segment_KNN_3_v2	5	""	90	""	9	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓	✓	3			No
Tentativa 19	Segment_SVM_0,9_100_v2	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	band 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Convexity, Roundness, Elongation, Main Direction	✓			0,9	100	No
Tentativa 20	Segment_SVM_0,9_100_v3	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6	Band 3, 6	Area, Rectangular Fit; Main Direction				0,9	100	No

Tentativa 21	Segment_KNN_3_V3	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 2, 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 1, 2, 3, 5, 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6	Band 3, 6	Area, Rectangular Fit; Main Direction	✓	3				No
Tentativa 22	Segment_SVM_Elongation_Factor_0,9_100	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor, Elongation			0,9	100		No
Tentativa 23	Segment_KNN_3_Elongation	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Elongation	✓	3				No
Tentativa 24	Segment_KNN_3_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor	✓	3				No
Tentativa 25	Segment_KNN_3_Elongation_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor, Elongation	✓	3				No
Tentativa 26	Segment_SVM_0,9_100_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor			0,9	100		No
Tentativa 27	Segment_SVM_0,9_100_Elongation	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Elongation			0,9	100		No
Tentativa 28	Segment_SVM_0,3_100_Elongation_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor, Elongation			0,3	100		No
Tentativa 29	Segment_SVM_0,3_100_Elongation	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Elongation			0,3	100		No
Tentativa 30	Segment_SVM_0,3_100_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor			0,3	100		No
Tentativa 31	Segment_KNN_1_Elongation_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor, Elongation	✓	1				No

Tentativa 32	Segment_KNN_5_Elongation_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor, Elongation	✓	5			No
Tentativa 33	Segment_KNN_9_Elongation_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor, Elongation	✓	9			No
Tentativa 34	Segment_SVM_0,1_100_Elongation_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor, Elongation			0,1	100	No
Tentativa 35	Segment_SVM_0,1_100_Elongation	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Elongation			0,1	100	No
Tentativa 36	Segment_SVM_0,1_100_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor			0,1	100	No
Tentativa 37	Segment_KNN_1_Elongation	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Elongation	✓	1			No
Tentativa 38	Segment_KNN_1_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor	✓	1			No
Tentativa 39	Segment_KNN_5_Elongation	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Elongation	✓	5			No
Tentativa 40	Segment_KNN_5_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor	✓	5			No
Tentativa 41	Segment_KNN_9_Elongation	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Elongation	✓	9			No
Tentativa 42	Segment_KNN_9_Factor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 5, 7	Band 1, 2, 4, 5, 6, 7, 8	Band 1, 2, 3, 5, 6, 7, 8	Band 6	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 3, 6, 8	Band 2, 3, 6, 8	Form Fractor	✓	9			No

Tentativa 43	Segment_KNN_1_All Bands_Ffactor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Form Fractor		✓	1			No
Tentativa 44	Segment_KNN_1_All Bands_Elongation_Ffactor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Form Fractor, Elongation		✓	1			No
Tentativa 45	Segment_SVM_0,9_1 00_AllBands_Elongati om_Ffactor	5	""	90	""	3	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Band 1, 2, 3, 4, 5, 6, 7, 8	Form Fractor, Elongation				0,9	100	No